



İSKENDERUN TEKNİK
ÜNİVERSİTESİ
LİSANSÜSTÜ EĞİTİM ENSTİTÜSÜ

**YÜKSEK
LİSANS
TEZİ**

**NEHİRLERDEKİ AKIŞ MİKTARININ
DESTEK VEKTÖR MAKİNELERİ
VE BULANIK MANTIK
YÖNTEMLERİ İLE MODELLENMESİ**

Büşra AK

**İNŞAAT MÜHENDİSLİĞİ
ANABİLİM DALI**

HAZİRAN 2021



**NEHİRLERDEKİ AKIŞ MİKTARININ DESTEK VEKTÖR MAKİNELERİ
VE BULANIK MANTIK YÖNTEMLERİ İLE MODELLENMESİ**

Büşra AK

**YÜKSEK LİSANS
İNŞAAT MÜHENDİSLİĞİ ANABİLİM DALI**

**İSKENDERUN TEKNİK ÜNİVERSİTESİ
LİSANSÜSTÜ EĞİTİM ENSTİTÜSÜ**

HAZİRAN 2021

Büşra AK tarafından hazırlanan “NEHİRLERDEKİ AKIŞ MİKTARININ DESTEK VEKTÖR MAKİNELERİ VE BULANIK MANTIK YÖNTEMLERİ İLE MODELLENMESİ” adlı tez çalışması aşağıdaki jüri tarafından OY BİRLİĞİ ile İskenderun Teknik Üniversitesi İnşaat Mühendisliği Anabilim Dalında YÜKSEK LİSANS TEZİ olarak kabul edilmiştir.

Danışman: Prof. Dr. Mustafa DEMİRCİ
İnşaat Mühendisliği, İskenderun Teknik Üniversitesi

Bu tezin, kapsam ve kalite olarak Yüksek Lisans Tezi olduğunu onaylıyorum.

.....
.....

Başkan: Prof. Dr. Mustafa DEMİRCİ
İnşaat Mühendisliği, İskenderun Teknik Üniversitesi

Bu tezin, kapsam ve kalite olarak Yüksek Lisans Tezi olduğunu onaylıyorum.

.....
.....

Üye: Prof. Dr. Murat ÖRNEK
İnşaat Mühendisliği, İskenderun Teknik Üniversitesi

Bu tezin, kapsam ve kalite olarak Yüksek Lisans Tezi olduğunu onaylıyorum.

.....
.....

Üye: Dr. Öğr. Üyesi Mehmet Eyyüp KAVŞUT
İnşaat Mühendisliği, Osmaniye Korkut Ata Üniversitesi

Bu tezin, kapsam ve kalite olarak Yüksek Lisans Tezi olduğunu onaylıyorum.

.....
.....

Tez Savunma Tarihi:

24/06/2021

Jüri tarafından kabul edilen bu tezin Yüksek Lisans Tezi olması için gerekli şartları yerine getirdiğini onaylıyorum.

.....

Doç. Dr. Ersin BAHÇECİ

Lisansüstü Eğitim Enstitüsü Müdürü

ETİK BEYAN

İskenderun Teknik Üniversitesi Lisansüstü Eğitim Enstitüsü Tez Yazım Kurallarına uygun olarak hazırladığım bu tez çalışmada;

- Tez üzerinde Yükseköğretim Kurulu tarafından hiçbir değişiklik yapılamayacağı için tezin bilgisayar ekranında görüntülendiğinde asıl nüsha ile aynı olması sorumluluğunun tarafıma ait olduğunu,
 - Tez içinde sunduğum verileri, bilgileri ve dokümanları akademik ve etik kurallar çerçevesinde elde ettiğimi,
 - Tüm bilgi, belge, değerlendirme ve sonuçları bilimsel etik ve ahlak kurallarına uygun olarak sunduğumu,
 - Tez çalışmada yararlandığım eserlerin tümüne uygun atıfta bulunarak kaynak gösterdiğimi,
 - Kullanılan verilerde herhangi bir değişiklik yapmadığımı,
 - Bu tezde sunduğum çalışmanın özgün olduğunu,
- bildirir, aksi bir durumda aleyhime doğabilecek tüm hak kayıplarını kabullendiğimi beyan ederim.

Büşra Ak

24/06/2021

NEHİRLERDEKİ AKIŞ MİKTARININ DESTEK VEKTÖR MAKİNELERİ VE BULANIK MANTIK YÖNTEMLERİ İLE MODELLENMESİ

(Yüksek Lisans Tezi)

Büşra AK

İSKENDERUN TEKNİK ÜNİVERSİTESİ
LİSANSÜSTÜ EĞİTİM ENSTİTÜSÜ

Haziran 2021

ÖZET

Su kaynaklarının verimli kullanılması, su yapılarının inşasının planlanması ve sel felaketlerinin önlenmesi için nehirlerdeki akış miktarının doğru tespiti önemlidir. Ancak doğru akış tahmini, nehir havzasının hidrolojik ve meteorolojik özelliklerinin iyi anlaşılmasıyla ilgilidir. Nehirlerdeki akış tahmini, su kaynaklarının amacına uygun kullanılması, su yapılarının projelendirilip planlanması ve doğal afetler karşısında önlem alınması açısından çok önemlidir. Günümüzde nehirlerde akış tahmini için farklı yapay zeka yöntemleri uygulanmaktadır. Bu çalışmada Destek Vektör Makinaları (SVM), Bulanık Mantık (Sugeno ve Mamdani) ve Çoklu Lineer Regresyon (ÇLR) metotlarının performansları karşılaştırılarak nehirlerde akış miktarı tahmini yapılmıştır. Çalışma alanı olarak, ABD Worcester şehrindeki Stilwater nehri seçilmiştir. Bulanık mantık, destek vektör makineleri ve çoklu doğrusal regresyon modellerinde girdi verilerini oluşturmak için günlük 1095 yağış, akış, sıcaklık verileri kullanılmıştır. Elde edilen sonuçlar ve gerçek sonuçlar karşılaştırılmıştır.

Anahtar Kelimeler : Akış tahmin; Bulanık mantık; Destek vektör makineleri; Çoklu doğrusal regresyon

Sayfa Adedi : 51

Danışman : Prof. Dr. Mustafa DEMİRCİ

MODELING OF RIVER FLOWS WITH SUPPORT VECTOR MACHINES AND FUZZY LOGIC METHODS

(M. Sc. Thesis)

Büşra AK

ISKENDERUN TECHNICAL UNIVERSITY
GRADUATE EDUCATION INSTITUTE

June 2021

ABSTRACT

Accurate determination of the amount of flow in rivers is important for efficient use of water resources, planning the construction of water structures and preventing flood disasters. However, accurate flow estimation is about a good understanding of the hydrological and meteorological characteristics of the river basin. Estimation of flow in rivers is very important in terms of using water resources for their intended purpose, designing and planning water structures and taking precautions against natural disasters. Today, different artificial intelligence methods are applied for flow prediction in rivers. In this study, the performance of Support Vector Machines (SVM), Fuzzy Logic (Sugeno and Mamdani) and Multiple Linear Regression (MLR) methods were compared and the flow rate in rivers was estimated. The Stilwater river in the USA Worcester Country was chosen as the study area. 1095 daily precipitation, flow and temperature data were used to generate the input data in fuzzy logic, support vector machines and multiple linear regression models. Obtained results and actual results were compared.

Key Words : Flow prediction; Fuzzy logic; Support vector machines; Multiple linear regression
Number of Pages : 51
Supervisor : Prof. Dr. Mustafa DEMİRCİ

TEŐEKKÜR

Tez alıőmamın her aőamasında tecrübesi ve bilgisiyle yanımda olan Prof. Dr. Mustafa DEMİRĐİ'ye teőekkür ederim. Ayrıca desteęini bizlerden esirgemeyen Arő. Gör. Bestami TAŐAR'a en iten duygularıyla teőekkürlerimi sunarım. Tez alıőmam sürecinde yardımlarından dolayı deęerli hocam Prof. Dr. Fatih ÜNEŐ'e de teőekkürü bor bilirim. Bu günlere gelmem de her zaman destek olan annem Sultan BATIK ve babam İsmail BATIK'a ve bana her daim güvenen inanan desteęini benden esirgemeyen tezimi tamamlarken gece gündüz demeden yanımda duran sevgili eőim Muhammed Kenan AK'a da sonsuz teőekkür ederim.



İÇİNDEKİLER

	Sayfa
ÖZET	iii
ABSTRACT	iv
TEŞEKKÜR	v
İÇİNDEKİLER	vi
ÇİZELGELERİN LİSTESİ	viii
ŞEKİLLERİN LİSTESİ.....	ix
SİMGELER VE KISALTMALAR.....	xii
1. GİRİŞ	1
2. ÖNCEKİ ÇALIŞMALAR.....	5
3. MATERYAL ve YÖNTEM	11
3.1.Çalışma Alanı	11
3.2. Kullanılan Modeller	15
3.2.1.Çoklu doğrusal regresyon (ÇDR)	15
3.2.2. Bulanık mantık	17
3.2.2.1 Bulanık küme kavramı	20
3.2.2.2 Bulanık çıkarım sistemi.....	22
3.2.2.3 Mamdani bulanık çıkarım sistemi.....	23
3.2.2.4 Uyarlamalı ağ tabanlı bulanık çıkarım sistemi (ANFIS)	25
3.2.3. Destek vektör makinesi (DVM)	25
4. ARAŞTIRMA BULGULARI ve TARTIŞMA	32
4.1. Model Performansında Kullanılan İstatistiksel Parametreler	32
4.2. Model Sonuçları	33
4.2.1. ÇDR model sonuçları.....	33
4.2.2. Sugeno-BM model sonuçları	36

4.2.3. Mamdani-BM model sonuçları.....	38
4.2.4. DVM model sonuçları.....	41
5. SONUÇ ve ÖNERİLER	45
KAYNAKLAR.....	47



ÇİZELGELERİN LİSTESİ

Çizelge	Sayfa
Çizelge 3.1. Stillwater nehrine ait büyüklükler	12
Çizelge 3.2. Klasik mantık ile bulanık mantık arasındaki farklar	18
Çizelge 4.1 Günlük akış miktarı tahmininde kullanılan model sonuçlarının karşılaştırılması.....	43



ŞEKİLLERİN LİSTESİ

Şekil	Sayfa
Şekil 1.1. Limnigraf	2
Şekil 1.2. Hidrolojik döngü	3
Şekil 3.1. Çalışılan istasyonun konumu	11
Şekil 3.2. Çalışılan istasyonun bulunduğu Stillwater nehri	13
Şekil 3.3. Çalışılan istasyondaki Stillwater nehrine ait 2014-2017 yılları arasındaki günlük sıcaklık miktarı değişimleri	13
Şekil 3.4. Çalışılan istasyondaki Stillwater nehrine ait 2014-2017 yılları arasındaki günlük yağış miktarı değişimleri.	14
Şekil 3.5. Çalışılan istasyondaki Stilwater nehrine ait 2014-2017 yılları arasındaki günlük debi miktarı değişimleri	14
Şekil 3.6. Çok değişkenli doğrusal regresyon	15
Şekil 3.7. Saçılım grafiği	16
Şekil 3.8. Yaşlılar kümesinin kesin ve bulanık küme ile gösterimi	20
Şekil 3.9. Yaşlı kesin kümesi.....	21
Şekil 3.10. Yaşlı bulanık kümesi	21
Şekil 3.11. Bulanık mantık örnekleme	22
Şekil 3.12. Bulanıklaştırma-Durulaştırma birimi bulanık sistem.	22
Şekil 3.13. Bulanık VE ve VEYA işlemleri için sırasıyla minimizasyon ve maksimizasyon operatörlerini kullanan mamdani tipi bulanık çıkarım sistemi	24
Şekil 3.14. Sinirsel bulanık sistemlerin sinir ağları ve bulanık mantık ile ilişkisi	25
Şekil 3.15. SVM'nin şematik gösterimi	26
Şekil 3.16. İki boyutlu uzayda örnek veri kümesi	27
Şekil 3.17. İki veri kümesini ayıran hiper düzlem örneği	28
Şekil 3.18. Doğrusal olarak sınıflandırılmayan SVM gösterimi	29

Şekil	Sayfa
Şekil 3.19. Doğrusal olarak sınıflandırılmayan girdi uzayının bir üst boyuta çekirdek fonksiyonu ile haritalanması	30
Şekil 3.20. Polinom çekirdek gösterimi	30
Şekil 3.21 Doğrusal olmayan 2 boyutlu örnek uzay gösterimi	31
Şekil 3.22 Radyal tabanlı fonksiyona ait çekirdek fonksiyonu	31
Şekil 4.1. Günlük akış miktarı eğitim verileri için ÇDR yöntemine ait saçılım grafiği	34
Şekil 4.2. Günlük akış miktarı eğitim verileri için ÇDR yöntemine ait ölçüm ve dağılım grafiği	34
Şekil 4.3. Günlük akış miktarı test verileri için ÇDR yöntemine ait saçılım grafiği.....	35
Şekil 4.4. Günlük akış miktarı test verileri için ÇDR yöntemine ait ölçüm ve dağılım grafiği	35
Şekil 4.5. Günlük akış miktarı eğitim verileri için Sugeno-BM yöntemine saçılım grafiği	36
Şekil 4.6. Günlük akış miktarı eğitim verileri için Sugeno-BM yöntemine ait ölçüm ve dağılım grafiği.	37
Şekil 4.7. Günlük akış miktarı test verileri için Sugeno-BM yöntemine ait saçılım grafiği	37
Şekil 4.8. Günlük akış miktarı test verileri için Sugeno-BM yöntemine ait ölçüm ve dağılım grafiği	38
Şekil 4.9. Günlük akış miktarı eğitim verileri için Mamdani-BM yöntemine ait saçılım grafiği.....	39
Şekil 4.10. Günlük akış miktarı eğitim verileri için Mamdani-BM yöntemine ait ölçüm ve dağılım grafiği	39
Şekil 4.11. Günlük akış miktarı test verileri için Mamdani-BM yöntemine ait saçılım grafiği	40
Şekil 4.12. Günlük akış miktarı test verileri için Mamdani-BM yöntemine ait ölçüm ve dağılım grafiği	40

Şekil	Sayfa
Şekil 4.13. Günlük akış miktarı eğitim verileri için DVM yöntemine ait saçılım grafiği	41
Şekil 4.14. Günlük akış miktarı eğitim verileri için DVM yöntemine ait ölçüm ve dağılım grafiği	42
Şekil 4.15. Günlük akış miktarı test verileri için DVM yöntemine ait saçılım grafiği	42
Şekil 4.16. Günlük akış miktarı test verileri için DVM yöntemine ait ölçüm ve dağılım grafiği	43



SİMGELER VE KISALTMALAR

Bu çalışmada kullanılmış simgeler ve kısaltmalar, açıklamaları ile birlikte aşağıda sunulmuştur.

Simgeler	Açıklamalar
Et	Evapotranspirasyon
et_0	Referans Evapotranspiration
r	Korelasyon katsayısı
rh	Bağıl Nem
r^2	Determinasyon katsayısı
sr	Solar Radyasyon
t	Sıcaklık
t_m	Günlük Ortalama Sıcaklık
t_{max}	Günlük Maksimum Sıcaklık
t_{mean}	Günlük Ortalama Sıcaklık
t_{min}	Günlük Minimum Sıcaklık
u	Rüzgâr Hızı
Kısaltmalar	Açıklamalar
AR(p)	Oto-regresif model
BM	Uyarlamalı sinirsel bulanık çıkarım sistemi
CIMIS	Kaliforniya Sulama Yönetimi Bilgi Sistemi
ÇLR	Çoklu Lineer Regresyon
FAO	Food and Agriculture Organization
FG	Bulanık genetik yaklaşım
GEP	Gen ekspresyon programlama
GFNN	Genelleştirilmiş birinci dereceden sinir ağı
GHNN	Genelleştirilmiş yüksek dereceli sinir ağı
GMLR	Genelleştirilmiş çok doğrusal regresyon
GRNN	Genelleştirilmiş regresyon sinir ağları
GT	Gama Test

İBGYYSA

İleri beslemeli geri yayımlı yapay sinir ağı

Kısaltmalar

Açıklamalar

KKOH

Ortalama karesel hataların karekökü

LSSVM-GT

En küçük kareler destek vektör makinesi-gama testi

MOH

Mutlak ortalama hata

OKH

Ortalama karesel hata

PET

Potansiyel buharlaşma transpirasyonu

PM

Penman-Monteith

RBNN

Radial Based Artificial Neural Networks

RTYSA

Radyal Tabanlı Yapay Sinir ağları

USGS

United States geological survey

YSA

Yapay sinir ağı


1. GİRİŞ

Su; canlıların yaşamlarını devam ettirmelerinde hayati önem taşır. Yeryüzünün dörtte üçünün sularla kaplı olduğu bilinmektedir. Bu oran bize ne kadar bol suyun olduğunu düşündürse de tüketilebilir su % 0.74 civarındadır. Dünyadaki tatlı suların ortalama %70 'i kutuplardaki buzullardan meydana gelir. Geriye kalan kısmı ise akiferlerdeki yer altı suyundan ve yüzeysel akıştan meydana gelir. Dünya nüfusunun giderek artması, sanayileşme, tüketim, israf ve çevre bilincinin yeterince oluşmaması yüzünden su kaynaklarının tüketim hızı gittikçe arttırmakta ve su miktarının azalmasına neden olmaktadır. Ülkemizde 2019 yılında baraj doluluk oranı %90.65 iken 2020 yılında %52.87'dir. 2021 yılının başlarında ise doluluk oranımız %28.66 olarak ölçülmüştür (İSKİ). Ülkemizdeki nehirlerin, derelerin, göllerin %79'u kanalizasyon suları, fabrika atıkları ve kimyasal atıklar gibi etkenlerden dolayı kirli durumdadır. Bu yüzden yaşamsal faaliyetlerin devamı için su tüketiminde önlem almak, su kirliliğinin önüne geçmek için gerekli bütün önlemleri almalı ve bu bilincin oluşmasına yardımcı olmalıyız.

Yüzey akışı, yağmur, dolu, kar olarak yeryüzüne düşen yağışın buharlaşma ve infiltrasyon (sızma) ile kaybolan kısmından geriye kalanının arazinin eğiminden faydalanarak akan kısmına akış veya yüzeysel akış adı verilmektedir. Akışa geçen suyun bir bölümü arazi üzerinde küçük çukurlarda birikirler. Özellikle dağlık yerlerde, eğimi fazla olan satırlarda, zeminin geçirimsiz olduğu, toprağın çok fazla erozyona uğradığı yerlerde, zeminin su tutma kapasitesinin çok az olduğu satırlarda şiddetli yağışların sonucunda akışa geçen su miktarı artmaktadır. Akış miktarını etkileyen faktörleri iki gruba ayırabiliriz. Bunlardan ilki doğrudan akışı etkileyen faktörler, diğeri ise doğrudan yüzeysel akışın dağılımını etkileyen faktörlerdir. Doğrudan akış miktarı; arazi yüzeyinin durumuna, yağışın miktarına, şiddetine, süresinin uzunluğu veya kısalığına, arazinin kullanılmasına, toprağın geçirgenliğine bağlıdır. Doğrudan yüzeysel akış dağılışı; drenaj havzasının şekli, büyüklüğü, arazinin eğimi ve suyun toplanma süresine bağlıdır.

Şekil 1.1 'de gösterilen yüzey akış miktarı ölçme yöntemlerinden biri olan limnigraf yöntemi, diğer ampirik formüllerle hesaplanan yöntemlerden daha sağlıklı ve doğru sonuçlar verir. Bu ölçme yönteminde havzanın çıkış ağzına bir limnigraf yerleştirilir ve yüzey akış miktarı hesaplanır. Genelde baraj, gölet vb. yapılar yapılmadan önce limnigrafı elde akış miktarı 2, 5, 10, 25, 50, 100 yılda gelecek maksimum yüzey akışı hesaplamak için kullanılır. Teorik veya ampirik özelliklerdeki formüllerle bir havzaya ait en yüksek yüzey akış miktarı

hesaplanabilmektedir. Fakat ampirik yöntemlerle hesaplanan yüzey akış miktarı ile ölçümler yapılarak bulunan yüzey akış miktarı arasında havzanın özelliklerine bağlı olarak farklılıklar olabilir. Bu sebeple ampirik formüllerle hesaplama yapılırken çok dikkatli olunmalıdır. Fazla hesaplanan yüzey akış miktarı baraj, regülatör gibi tesislerin yapımında yüksek maliyetlere sebep olurken, düşük yüzey akışı ile hesapları yapılan tesislerde, hesaplanandan daha fazla gelen yüzey akış miktarının etkisiyle yıkımlar meydana gelerek can ve mal kaybına sebep olur.




Şekil 1.1. Limmigraf (USGS,2021)

Nehir, yerçekiminin etkisiyle yüksek yerlerden alçak yerlere doğru hareket eden su kütlelerinden oluşur. Yer yüzeyi her zaman düz değildir. Bir yöne doğru eğimlidir. Akan su ilk olarak ufak dereler şeklinde yokuş aşağı akar. Ufak dereler ilerlerken kendilerinden daha büyük akarsu ve nehirleri oluşturmak için birleşirler. Nehirler bu akışın sonucunda denizlere veya okyanuslara ulaşırlar. Su dört bir yanı yüksek arazilerle kapalı bir yere akarsa burada göl oluşturur. Yeryüzündeki okyanuslarda ve denizlerde bulunan suların buharlaşma ile atmosfere, atmosferden tekrar yeryüzüne, yüzeysel akış ve yeraltı suyu ile nehirlere, nehirlerdeki akış ile tekrar okyanuslara ve denizlere ulaştığı bu döngüye hidrolojik döngü, hidrolojik çevrim veya su döngüsü denir (Şekil 1.2).

Yeryüzüne düşen yağışın bir bölümü yeraltına süzülür (infiltrasyon). Bu suyun birazı bitkiler tarafından emilir. Yapraklardan terlemeyle (transpirasyon) atmosfere tekrar gönderilir. Geride kalan su ise yeraltı suyu veya kaynaklar ile nehirleri ve gölleri oluşturur. Yağışlar

halinde yeryüzüne inen suyun hepsi yeraltına sızmaz. Sızmayıp kalan su yüzeyde bir akış oluşturur. Bu akışın büyük çoğunluğu nehirler ve akarsular yardımıyla tekrar denizlere ve okyanuslara ulaşır.



Şekil 1.2. Hidrolojik döngü (USGS,2021)

Şekil 1.2’de kara ve deniz arasındaki su alışverişinin dengede olduğu görülmektedir. Denizlerde ve okyanuslarda yağıştan çok buharlaşma meydana gelir. Şekilde görüldüğü gibi buharlaşma yağıştan 36 birim daha fazladır. Bunun aksine karadaki yağış miktarı da buharlaşma miktarından daha fazladır. Sonuç olarak karadan gelen yüzeysel akış ile deniz veya okyanuslarda oluşan buharlaşma miktarı birbirini dengede tutar.

Nehirler sadece insan yaşamında değil, dünyadaki tüm canlılar için önemlidir. Bitkiler ve hayvanlar yaşamlarını devam ettirebilmek için genelde nehirlerin etrafında büyür ve toplanırlar.

Ülkemiz yeryüzü şekillerine ve iklim çeşitliliğine bağlı olarak sık bir akarsu ağına sahiptir. Bu akarsuların çoğu dağlardan bir kısmı da yaylalardan ve ovalardan doğarak havzalara gider. Ülkemizin çoğunluğunun yarı kurak bir iklimde olması, az yağış alması ve akarsularının boylarının kısa olması taşıdıkları su miktarının az olmasına neden olur. En önemli özelliklerinin biri de çok fazla eğimli olmalarıdır. Bu yüzden de hidroelektrik enerji potansiyelleri oldukça yüksektir. Çok fazla eğimli oldukları için akış hızları da fazladır bu yüzden akarsu taşımacılığına elverişli değildirler. Nehirlerimizde akış ve su kullanımı

arasında ters bir orantı vardır. Kısacası su kullanımının fazla olduğu zamanlarda nehirlerimizdeki akış az, su kullanımı az olduğunda nehirlerimizde ki akış miktarı fazladır. Akarsuların akışındaki bu düzensizlik akarsuları kontrol etme isteği doğurmuştur. Bu yüzden akarsu ve nehirlerdeki akış miktarını korumak için baraj, regülatör gibi akarsuyu kontrol altına alacak tesisler kurulmuştur. Özellikle nehirlerdeki debi, seviye, akış miktarı gibi parametrelerinin tahmininin yapılması; akarsu ulaşımının belirlenmesinde, kuraklık yaşanan zamanlarda hidroelektrik üretiminin yapılmasında, taşkınların olacağı uyarısı yapılması ve taşkın zararlarının önlenmesinde, akarsu potansiyelinin belirlenmesinde, sulamanın ve şehir sularının dağıtımında, su kaynaklarının verimli ve amacına uygun kullanılmasında, su yapılarının inşasının planlanması ve hayata geçirilmesinde hayati önem taşır. Bu parametrelerin önceden tahmin edilebilmesi için hidrolojik çalışmalara ihtiyaç vardır. Akarsu nehir ve göllerin yıl boyunca su miktarlarının ölçümlerinin yapılması ve bunların incelenmesi gerekmektedir. Ülkemizde bu amaçla kurulmuş ilk Akarsu Gözlem İstasyonu (AGİ) 1935 yılında kurulmuş ve 1936 yılında hidrolojik ölçümler yapmaya başlamıştır.

2. ÖNCEKİ ÇALIŞMALAR

Geçmişten bugüne birçok araştırmacı nehirde akış ile ilgili farklı çalışmalar yapmıştır.

Fırat (2007), çalışmasında Türkiye'nin güneyinde bulunan Seyhan havzasını seçmiştir. Uçtepe debi istasyonundan günlük nehir akış verilerini almıştır ve toplamda 5114 veri kullanmıştır. Çalışmasında günlük nehir akışı tahmini yapabilmek için Yapay Sinir Ağı (YSA) yöntemi, Uyarlanabilir Nöro-Bulanık Çıkarım Sistemi (ANFIS) yöntemi, İleri Sinir Ağları (FFNN) yöntemi ve Genelleştirilmiş Regresyon Sinir Ağları (GRNN) yöntemini kullanmıştır. Bulduğu tüm sonuçların performanslarını karşılaştırıp değerlendirdikten sonra elde edilen sonuçlar ANFIS modelinin GRNN ve FFNN modeline göre daha başarılı sonuç verdiğini gözlemlemiştir.

Fırat (2008), nehirlerdeki akış tahmini için Seyhan Nehri ve Cine Nehrini seçmiştir. Çalışmasında ANFIS, GRNN ve FFNN yöntemleri kullanarak günlük nehir akış tahmini yapmıştır. Seyhan nehri için günlük nehir akış kombinasyonlarını kullanarak modelini oluşturmuştur. Cine nehri için ise nehirlerdeki günlük yağış ve debi verilerini kullanmıştır. İki nehir içinde verileri eğitim, test ve doğrulama olarak üç farklı alt gruba ayırmıştır. Sonuçlarda ANFIS modelinin GRNN ve FFNN modellerinden daha başarılı olduğunu gözlemlemiştir.

Özger (2009), çalışmasında Mamdani ve Takagi-Sugeno (TS) bulanık sistemlerini akış değerlerini tahmin etmek için karşılaştırmıştır. Çıktıları tahmin etmek için Takagi-Sugeno bulanık çıkarım sisteminde girdilerin doğrusal fonksiyonlarıyla, Mamdani'de ise çıktıları bulanık alt kümeler yardımı ile belirlemiştir. Bu iki yöntemi de Türkiye 'deki Fırat Nehrinde denemiştir. İki yöntemi de uygularken akış tahminlerinde dışsal etkenleri (yağış gibi) kullanmamıştır. İki modelinde avantajlarına ve dezavantajlarına bakmıştır. Mamdani Bulanık Çıkarım Sistemi, hata oranlarına bakıldığında Takagi-Sugeno sistemine göre daha iyi sonuç verdiğini gözlemlemiştir.

Farboudfam, Ghorbani ve Alami (2009), çalışmalarında nehirde akış tahmini yapmak için genetik progamlama kullanmışlar ve tahmin doğruluğu için hafıza kuralını araştırmışlardır. Araştırmalarında 1997-2001 yılları arası Urmia gölü havzasındaki Ligvan Nehrinin verilerini kullanmışlardır. Günlük zaman serileriyle beş günün üzerindeki akış drenajını, genetik programlama ile modellemek için kullanmışlardır. Nehirde akış tahmininde yapay sinir ağları uygulamasının genetik progamlamaya göre daha doğruluğun az olduğunu

görmüşlerdir. Sonuç olarak nehir akış tahmininde genetik programlamanın başarıyla kullanılabilceğini bulmuşlardır.

Keskin ve Taylan (2009), Türkiye'nin güneyinde bulunan Manavgat çayının nehir akış tahminini yapabilmek için ANFIS ve YSA yöntemlerini uygulamışlardır. Manavgat çayının akış tahminini yapmak için farklı havzalarda bulunan Dalaman çayı, Alara çayı ve Göksu çayının verilerini kullanmışlardır. ANFIS ve YSA modelleri 3 girdi ve 1 çıktıdan oluşturmuşlardır. Karşılaştırmalar sonucu aylık akış ölçümlerinde ANFIS modeli YSA modelinden daha iyi durumda olduğunu gözlemlemişlerdir. Eksik veya ölçülmemiş verilerde ANFIS modeliyle tahmin edilebileceğini bulmuşlardır.

Saplıoğlu ve Çimen (2010), Köprüçay Nehri 500x500 metre boyutlarında kutulara ayırmışlardır. Her bir kutuya eğim, jeolojik yapı ve bitki örtüsü verilerini işlemişlerdir. Her bir kutunun akış verilerini bulanık mantık modeli kullanarak tespit etmişlerdir. Havzaya etki eden yağış istasyonlarını ve havzada ki etkilerini de Thiessen çokgenlerini kullanarak bulmuşlardır. Havzaya etki eden yağış istasyonlarında veri eksikliklerinin olduğunu farkına varılmış ve eksikliklerin giderilmesi için çoklu regrasyon, yapay sinir ağları, harmonik ortalama ve ağırlıklı ortalama yöntemlerinden faydalanmışlardır. Kurulan bütün modeller arasından kullanılabilir model tespit etmişlerdir. İleriki aşamada, akış ve yağış verileri kullanılarak her yağış sonucunda her bir kutu da ayrı ayrı oluşabilecek akış miktarı bulmuşlardır. Bu aşamada debi ölçüm istasyonlarından faydalanılmış ve verilerin sadece yağışa bağlı olmadığı önceki günlerde ki yüzeysel akış ve taban akışı değerlerinin de etkili olduğunu düşünmüşlerdir. Modeldeki verileri arttırmışlar ve eksik verilerinde tamamlanabilmesi için YSA kullanılarak yöntemi daha da geliştirmişlerdir. Yapılan bu modelin eldeki verilerle testini yapmışlar ve kullanılabilir olduğu belirlemişlerdir.

Bisht ve Jangid (2011), bu çalışmada nehirlerdeki akış tahmini için ANFIS ve Doğrusal Çoklu Regresyon (MLR) yöntemlerini geliştirmişlerdir. YSA modelleri ve Bulanık Mantık modellerinin nehirlerdeki akış tahmini için uygulanabilir olduğunu gözlemlemişlerdir. Geliştirilen modellerle Gadavri nehrinin verilerini eğitmiş ve test etmişlerdir. Verileri karşılaştırdıklarında geliştirilen ANFIS modelleri, MLR gibi geleneksel modellerden daha iyi sonuç verdiğini gözlemlemişlerdir.

Yarar (2014), çalışmasında Wavelet-Neuro Fuzzy (WNF) modelini kullanarak Türkiye'deki Sakarya Havzasına ait 5 akış gözlem istasyonunun akış verilerini tahmin etmeye çalışmıştır.

Aynı verilerin doğruluğunu değerlendirmek için Otomatik Gerilimli Entegre Hareketli Ortalama (ARIMA) modelini kullanmıştır. Ortalama Karekök Hatalarıyla (RMSE) modellerin karşılaştırmalarını yapmıştır ve sonuç olarak nehirde akış tahmininde WNF modelinin ARIMA modeline göre daha doğru sonuçlar verdiğini gözlemlemiştir.

He, Wen, Lui ve Du (2014), çalışmalarında 3 adet farklı veriye dayalı, YSA, ANFIS ve Destek Vektör Makineleri (SVM) yöntemlerini kullanmışlardır. Çinin kuzeybatısında yarıkurak dağ bölgesinde bulunan nehir akış değerlerini farklı kombinasyonlarla analiz etmişlerdir ve en uygun girdi vektörünü seçmişlerdir. Eğitim ve doğrulama testleri sonucunda ANFIS, YSA, ve SVM modellerinin performanslarını karşılaştırmışlardır. Kullanılan üç modelde nehir akış tahmini için uygun modeller olarak seçilmiştir.

Rezaei, Motlaq, Mahmoudi, Mousavi (2015), çalışmalarında YSA kullanarak nehirde akışı tahmin etmeye çalışmışlardır. Bunun için Khonik Olya hidrometrik ve Ghayen Sinoptik istasyonlarının 1976-1977 yağış akış verilerini kullanarak 2010-2011 yılı yağışları ve nehir akışlarını tahmin etmişlerdir. MATLAB ile hesaplamalar yapmışlardır. Yapay Sinir Ağını modellemek için verilerin %85'ini önerilen yöntem kalan %15'ini ise yöntemi doğrulamak için kullanmışlardır. Her ay için %5'in altında bir hata geliştirmişlerdir. Sonuç olarak yağış nedeniyle meydana gelen yüzey akışını tahmin etmede Yapay Sinir Ağının uygun olduğu sonucuna varmışlardır.

Uamusse, Ndalila, Tsamba, Oliveria ve Person (2015), çalışmalarında aylık akış tahminini Dalgacık Sinir Ağı kullanarak araştırmışlardır. Pungwe nehri boyunca Vanduzi istasyonundan gelen verileri kullanarak hidroelektirik santralinde enerji üretmek için aylık akış tahmini modellerini kullanmışlardır. Sekiz farklı sinirsel aylık akış tahmin modelleri geliştirmişlerdir. Araştırmalar sonucu YSA en iyi performansa sahip olduğunu gözlemlemiştir.

Sönmez, Çeribaşı ve Doğan (2016), akış tahmininde YSA uygulamasını ve kısa tahminlerde trend analizi yöntemlerinin uygulamasını yapmışlardır. Tahminlerinde Sakarya Nehrinin 1989-2000 yılları arası akış verilerini kullanmışlardır. 4018 tane günlük akış verilerini YSA modelleri için eğitim ve test setleri olarak gruplandırmışlardır. Bu verilerin 2650'si eğitim için kalanını da test için ayırmışlardır. Akışı tahmin etmek için Sakarya nehrinin verilerini 7 farklı seneryonun 4'ünü farklı YSA modelleri ile analiz yapmışlardır ve üçünde de farklı trend analiz yöntemleri kullanmışlardır. Performans kriterlerini Ortalama Mutlak Hataya

(MAE), nash-sutcliffe yeterlilik puanına (NSSS) ve korelasyon katsayısına (R) bağlamamışlardır. Sonuçları birbiriyle karşılaştırmışlardır ve uzun vadeli akış tahmini için Mam-Kendall testi ve Spearman Rho testi kullanmışlardır. Analizler sonucu ileri beslemeli sinirsel ağlarının (FFNN) kısa vadeli tahminlerde en iyi sonucu verdiğini gözlemlemişlerdir.

Anusree ve Varhese (2016), çalışmalarında günlük akış tahminini Thrissur bölgesinde bulunan Karuvannur nehrinin havza çıkışından aldıkları verilerle yapmışlardır. Çalışmalarında çoklu doğrusal olmayan regresyon (MNLR) yöntemi, YSA yöntemi ve ANFIS yöntemlerini kullanmışlardır. Dokuz tane yağmur istasyonundan yağış verisi olarak modellerini daha da geliştirmişlerdir. Kombinasyonları farklı yağış-akış ve farklı zaman verilerinden oluşturmuşlardır. Modeller RMSE ve Nash-Sutcliffe katsayıları ile değerlendirmişlerdir. Sonuç olarak günlük akış tahminin de ANFIS modelinin YSA ve MNLR yöntemlerine göre daha sağlıklı tahminler verdiğini gözlemlemişlerdir.

Bardzadeh, Sarukkalige ve Jayawardena (2018), çalışmalarında ANFIS üzerindeki verileri yeniden işleme teknikleri uygulanarak daha gelişmiş bir akış tahmini modeli geliştirmişlerdir. WNF modelini geliştirmek için, Dalgacık Çoklu Çözünürlük Analizi ve ANFIS modelini birleştirmişlerdir. Avusturalyadaki Ellen Brook River ve Western'deki Railway Parade istasyonlarından aylık akış tahminlerini almışlardır. Daha sonra dalgacık katsayılarını nöro-bulanık modelle birleştirmişlerdir. Modeller bir sonraki aşamada Takagi-Sugeno-Kang Bulanık Çıkarım Sistemine bağlı olarak geliştirmişlerdir. Ortalama karesel hata ve Nash-Sutcliffe katsayıları performans olarak seçmişlerdir. Çalışmaların sonunda ANFIS modeli ile WNF modellerinin özellikle uzun süreli tahminlerde daha iyi sonuçlar verdiğini gözlemlemişlerdir.

Taşar, Üneş ve Varcin (2019), çalışmalarında Neuro-Fuzzy (NF) ve SVM yöntemlerini kullanmışlardır. Günlük yağış ve akış hidrolojik verilerini Muskegon'dan almışlardır. ABD havzasından alınan toplamda 1397 günlük yağış ve sıcaklık verileri NF ve SVM metotları kullanılarak analiz etmişlerdir. Modelden alınan sonuçlarla havzadan alınan günlük gözlemleri karşılaştırmışlardır. Karşılaştırmadan elde ettikleri sonuçlara göre SVM yönteminin yağış-akış tahmininde az hata verdiğini gözlemlemişlerdir. Sonuç olarak SVM yönteminin yağış-akış tahmininde bilinen klasik yöntemlerin yanında alternatif olarak kullanılabileceğini görmüşlerdir.

Üneş, Demirci, Zelenakova, Çalışıcı, Taşar, Vranay ve Kaya (2020), çalışmalarında nehirdeki akışı MLR, YSA, M5 Karar Ağacı (M5T), ANFIS, Mamdani-Bulanık Mantık (M-FL) ve Basit Üyelik İşlemleri ve Bulanık Kural Oluşturma Tekniği (SMGRT) modellerini kullanarak tahmin etmeye çalışmışlardır. ABD 'deki Sterling bölgesinde bulunan Stilwater Nehrini çalışma bölgesi olarak seçmişlerdir ve bu bölgedeki verileri kullanmışlardır. Girdi verileri tüm modellerde suyun sıcaklığı, günlük yağış ve nehir akışı olarak belirlemiştir. Modellerden elde edilen sonuçlar ile kaydedilen değerleri karşılaştırıp sonuçları istatistiksel olarak değerlendirmişlerdir. Her model için kolerasyon katsayısını (R), ortalama kare hatasını (MSE), ortalama mutlak hatasını (MAE) hesaplamışlardır. Karşılaştırılan sonuçlara göre M-FL ve SMGRT'nin nehirde akış tahmininin yapılmasında diğerlerine göre daha iyi sonuçlar verdiği farketmişlerdir.

Belvederesi, Dominic, Hassan, Gupta ve Achari (2020), çalışmalarında yeni bir teknikle akışı tahmin etmek için Kanada Alberta'daki Athabasca Nehrini çalışma alanı olarak belirlemiştir. Çalışmalarında bir girişli sıralı ANFIS modelini kullanmışlardır. Dört istasyon arasındaki teslim sürelerini tahmin ettikten sonra veri olarak kaynağın yakınlardaki ölçülen verileri kullanmışlardır. Bu yöntemin sonuçları dört hidrometrik istasyonun her birinden sıralı olmayan ve çok girişli ANFIS'lerle karşılaştırmışlardır. Çalıştıkları bu yöntem uzun mesafelerde doğru verileri sağladığını ve uzun sürelerde akışı tahmin etmeye elverişli olduğunu görmüşlerdir.

Yadav, Prasad, Mojjada, Kathamasu ve Joshi (2020), çalışmalarında nehirde akış tahmini için akıllı hibrit yapay zeka modelini geliştirmişlerdir. Hindistandaki Mahanadi nehrinin aylık akış tahminini genetik algoritma tabanlı Yapay Sinir Ağı (GA-YSA) kullanarak yapmışlardır. GA-YSA modelinin geliştirilmesi için Mahanadi nehrinin en son akış istasyonu olan Tikarapara ölçüm istasyonundan 20 yıllık akış verilerini toplamışlardır. Yağış, su seviyesi, tortu verimi, sıcaklık gibi parametreler YSA tahmin modelini geliştirmek için kullanmışlardır. GA-YSA modelinin performansını YSA modeli ile karşılaştırmışlardır. Sonuçlara göre GA-YSA modelinin nehirde akış tahmin etmede YSA modeline göre daha iyi performans gösterdiğini gözlemlemişlerdir.

Bu tez çalışmasında, nehirde akış miktarı tahmini yapılmıştır. SVM, Bulanık Mantık ve ÇLR metotlarının performansları karşılaştırılarak nehirde akış miktarı tahmini yapılmıştır. Nehirde akış miktarının tahmini için ortalama sıcaklık, debi ve yağış parametreleri

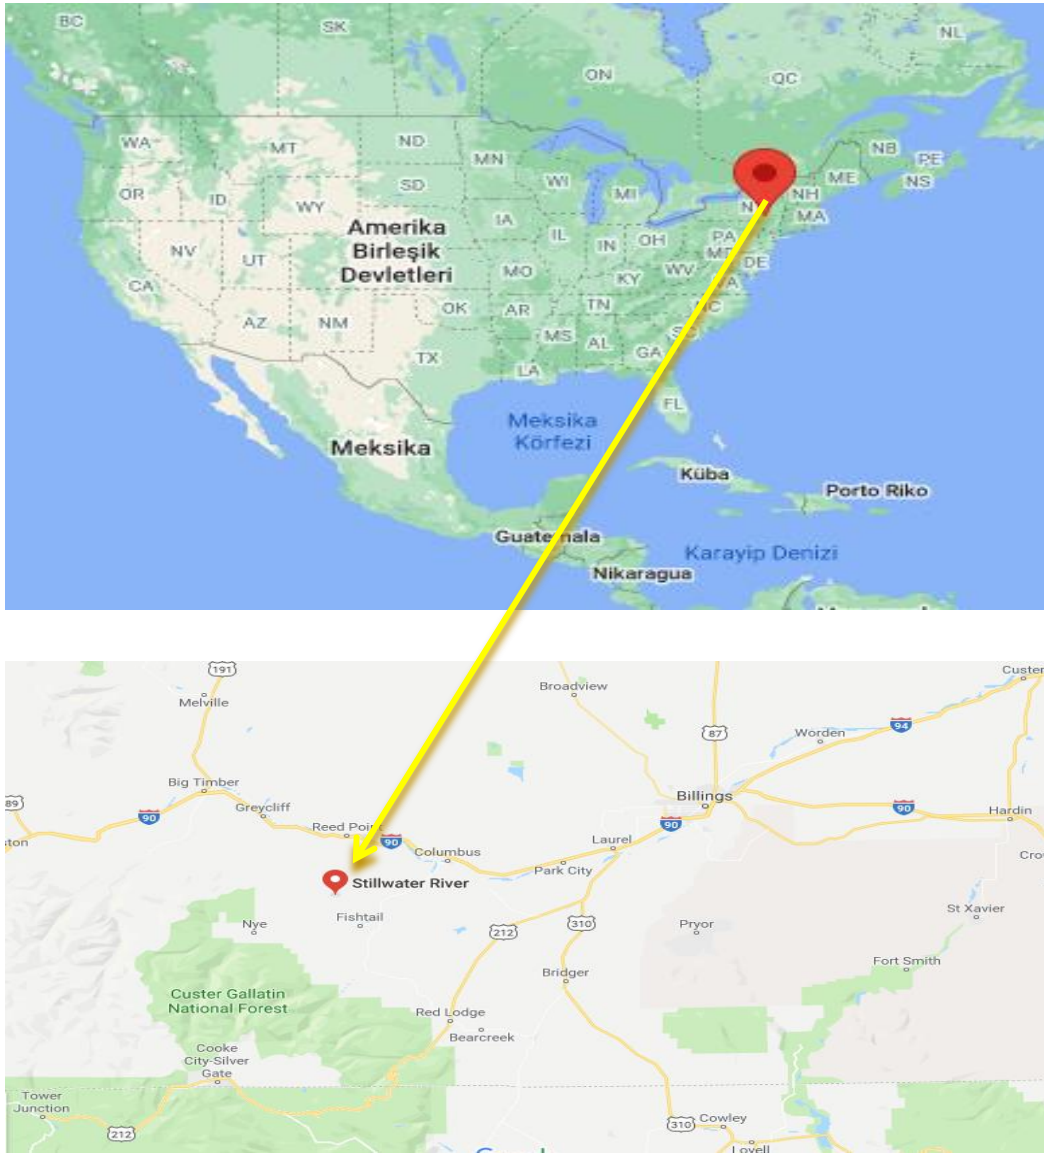
kullanılmıştır. Farklı girdi parametreleri kombinasyonları oluşturularak SVM , ÇLR ve bulanık mantık metotları kullanılarak sonuçlar karşılaştırılmıştır.



3. MATERYAL VE YÖNTEM

3.1. Çalışma Alanı

Bu çalışmada, Amerika Birleşik Devletleri'nin Sterling şehrinde bulunan Worcester ilçesindeki Stillwater nehri civarındaki Massachusetts-Rhode Island Su Bilim Merkezi tarafından yönetilen bir istasyona ait veriler kullanılmıştır. $42^{\circ}24'39''$ K enlemi ve $71^{\circ}47'30''$ Doğu boylamı üzerindeki bu istasyona ait 2014-2017 yılları arasındaki 3 yıllık meteorolojik veriler kullanılmıştır. Kullanılan veriler USGS (United States Geological Survey) web sayfasından alınmıştır. Çalışma istasyonunun görseli Şekil 3.1'de gösterilmiştir.



Şekil 3.1. Çalışma istasyonunun konumu (Google Maps, 2021)

Worcester şehri Amerika Birleşik Devletlerinin Massachusetts eyaletinde bulunan bir şehirdir. Worcester şehrinin 2016 rakamlarına göre nüfusu 184.508 olarak belirlenmiştir. Worcester, Massachusetts'in merkezine olan yakınlığı sebebiyle Commonwealth'in kalbi olarak bilinir. Konum olarak Boston'un yaklaşık 64 km batısında, Springfield'in 80 km doğusundadır. Worcester'in en kurak aylarda bile yağış miktarı oldukça fazladır ve soğuk ve ılıman bir iklim gözlenmektedir. Köppen-Geiger iklim sınıflandırmasına göre Dfa şeklinde isimlendirilir. Yıllık ortalama sıcaklığı 9.4 °C. Yıllık ortalama yağış miktarı 1159 mm'dir. Worcester, Blackstone Kanalı ve demiryolu taşımacılığı sebebiyle 19. yüzyılda tel, makine ve tekstil üreten bir sanayi şehri olarak gelişmiştir. Şehir nüfusunun çoğunu Avrupalı göçmenler oluşturmuştur. Fakat şehrin üretimi 2. Dünya savaşından sonra azalmıştır. Şehrin 1990'lı yıllardan sonra yüksek öğrenim, tıp, biyoteknoloji ve yeni göçmenler sayesinde ekonomi ve nüfusta artışlar başlamıştır. Worcester şehri Brezilyalılar, Portorikolular, Dominikliler, Vietnamlılar, Arnavutlar, Ganalılar ve diğer toplulukların çeşitliliği ve göçmen nüfusu ile bilinmektedir. Worcester şehrinde dokuz ayrı kolej ve üniversite vardır. Worcester'de mimari olarak 19. yüzyıldan kalma çok sayıda üç katlı evler bulunmaktadır. Worcester, Orta Massachusetts'in ana şehridir ve önemli bir istihdam ve ulaşım merkezidir. Çizelge 3.1'de Stillwater nehrine ait büyüklükler verilmiştir.

Çizelge 3.1. Stillwater nehrine ait büyüklükler (Wikipedia, 2021)

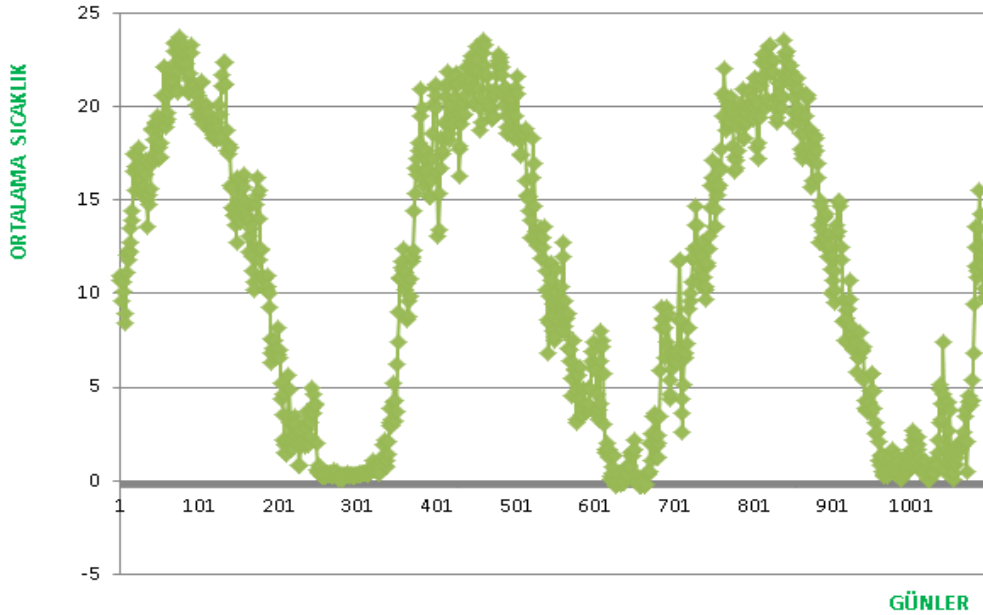
Yükseklik	720 ft (220 m)
Uzunluk	8.1 mil (13,0 km)
Havza boyutu	39,3 mil kare (102 km ²)

Şekil 3.1 ve Şekil 3.2'de bu çalışmada kullanılan verilerin alındığı Stilwater Nehrinin genel görünümü ve seçilen bölgenin dünya üzerindeki konumunun gösterildiği haritalar verilmiştir.




Şekil 3.2. Çalışılan istasyonun bulunduğu Stillwater Nehri (USGS, 2021)


Bu çalışmada Worcester şehrindeki Stillwater nehri civarındaki bir istasyona ait 2014 – 2017 yılları arasındaki 3 yıllık toplamda 1095 tane meteorolojik ölçüm verileri kullanılmıştır. Nehirde akış tahmini için ortalama sıcaklık, yağış ve debi parametreleri kullanılmıştır. Verilerin %75'i eğitim ve %25'i test için kullanılacaktır. Veriler USGS (United States Geological Survey) sayfasından alınmıştır Çalışılan istasyondaki Stillwater nehrine ait 2014-2017 yılları arasındaki 1095 günlük veriler değişimleri Şekil 3.3, Şekil 3.4, Şekil 3.5'de verilmiştir.



Şekil 3.3. Çalışılan istasyondaki Stilwater Nehrine ait 2014-2017 yılları arasındaki günlük ortalama sıcaklık miktarı değişimleri



Şekil 3.4. Çalışılan istasyondaki Stilwater Nehrine ait 2014-2017 yılları arasındaki günlük yağış miktarı değişimleri




Şekil 3.5. Çalışılan Stilwater Nehrine ait 2014-2017 yılları arasındaki günlük debi miktarı değişimleri

3.2. Kullanılan Modeller

Amerika Birleşik Devletleri Jeolojik Araştırma Enstitüsü (USGS)'den elde edilen Stillwater nehrinin yakınlarındaki bir istasyona ait 2014-2017 yılları arasındaki akış verileri ÇLR, bulanık mantık ve SVM yöntemleri kullanılarak akış miktarı tahmin edilmeye çalışılmış ve sonuçlar değerlendirilmiştir. Nehirde akış tahmini için debi, ortalama sıcaklık, yağış parametreleri kullanılmıştır.

3.2.1.Çoklu doğrusal regresyon (ÇDR)

ÇDR modelinde temel amaç açıklayıcı değişkenler ya da regresörler yardımıyla yanıt değişkenindeki toplam değişimi bulmaktır. Yani bir tane bağımlı değişken ile bu değişkenle ilişkisi olan bir dizi bağımsız değişken arasındaki bağlantıyı ortaya koymak için yapılan analizdir. Başka bir tanımla ÇDR bağımlı değişkeni doğrusal bir artış gösteren ve birden fazla değişkene bağlı olan bu değişkenler arasındaki bağlantıyı bulmaya yarayan yöntemdir. Şekil 3.6'da y bağımsız değişkeninin 2 bağımlı (x_1 - x_2)n değişkene ait değişimi gösterilmiştir.



Şekil 3.6. Çok değişkenli doğrusal regresyon (Wikipedia,2021)

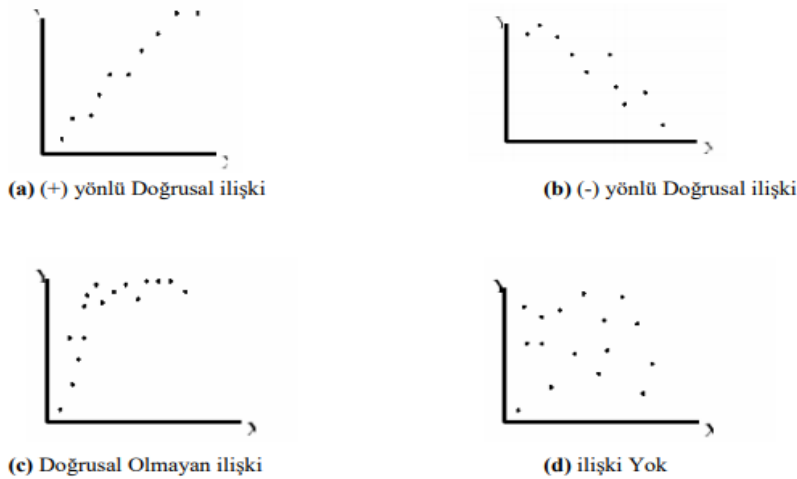
$$\text{Basit Doğrusal Regresyon} \quad y = b_0 + b_1 * x_1 \quad (3.1)$$

$$\begin{array}{c} \text{Bağımlı Değişken} \quad \quad \quad \text{Bağımsız Değişken} \\ \downarrow \quad \quad \quad \downarrow \quad \downarrow \quad \downarrow \\ \text{Çoklu Lineer Regresyon} \quad y = b_0 + b_1 * x_1 + b_2 * x_2 + \dots + b_n * x_n + e \end{array} \quad (3.2)$$

Burada $b_0, b_1, b_2, \dots, b_n$ bilinmeyenlerine regresyon katsayısı denir. e 'ye ise hata terimi adı verilir. ÇDR bağımsız değişkenlerin bağımlı değişkenlere etki derecesi birbirinden farklıdır. Bundan dolayı çoklu doğrusal regresyonda her değişkenin katsayısı aynı olmak zorunda değildir. b regresyon katsayısını kısaca açıklamak gerekirse bağımlı değişkenler ile bağımsız değişkenler arasındaki ilişkiyi ifade eder.

Bağımlı değişken (y) modelde açıklanan veya tahmin edilen değişkendir. Bu değer bağımsız değişken ile ilişkili olduğu tahmin edilir. Bağımsız değişken (x) ise modelde açıklayıcı değişkendir. Bağımlı değişkeni tahmin etmede kullanılır.

Değişkenler arasında doğrusal bir ilişki olabileceği gibi doğrusal olmayan bir ilişki de olabilir. Bu nedenle saçılım grafiği yapılmadan regresyon analizine karar verilmemesi gerekir. Şekil 3.7'de bağımlı ve bağımsız değişkenler arasındaki ilişkiyi gösteren saçılım grafikleri gösterilmiştir.



Şekil 3.7. Saçılım grafikleri

Basit doğrusal regresyon analizinde bir bağımlı ve bir bağımsız değişken varken çoklu doğrusal regresyon analizinde bir bağımlı değişken varken birden fazla bağımsız değişken vardır. Basit doğrusal regresyon ve çoklu doğrusal regresyon analizlerinde değişkenler arasında doğrusal bir ilişki vardır. Bağımlı ve bağımsız değişkenler arasında eğrisel bir ilişki varsa eğrisel regresyon modeli ile açıklanır.

Herhangi bir regresyon katsayısı diğer değişkenlerin etkisi kaldırıldığında bağımsız değişkendeki ortaya çıkan bir birimlik değişmeye karşılık bağımlı değişkendeki değişiklik

miktarını vermektedir. R^2 (Determinasyon) katsayısı değeri 0-1 arasında olmalıdır. R^2 değeri ne kadar yüksek olursa modeldeki veriler o kadar iyi uyum sağlıyor demektir.

Çoklu doğrusal regresyon modeli oluştururken basit doğrusal regresyonun aksine daha çok dikkat etmemiz gereken şeyler vardır. Hangi değişkenin önemli olup olmadığını bilmek ÇDR için oldukça önemlidir. Bağımlı değişkeni etkileyen bir veriyi kaldırdığımız zaman oluşacak hata veya gereksiz bir veriyi kaldırmadığımız zaman kaybedilecek verim bize büyük hatalar olarak döner. Bundan dolayı verileri doğru seçebilmek için istatistik bilimiyle uğraşan insanlar çeşitli yöntemler geliştirmişlerdir. Bu yöntemler;

Enter metodu

Bağımsız değişkenlerin tek adımda girilip değerlendirildiği metottur.

Geriye doğru eleme (eliminasyon)

Yöntemde modeldeki tüm değişkenler içerisinde fazlalıkları çıkararak verimli modeli oluşturmak için kullanılan bir yöntemdir. Öncelikle kısmi korelasyon katsayısı en küçük olan değer incelenir. Öngörülen değerlerden büyük olan değerler elenerek devam edilir.

İleri doğru eleme

Bu yöntem geriye doğru eleme yönteminden biraz farklıdır. Hiçbir bağımsız değişken içermeyen bir modelden başlanarak verimli olduğu tahmin edilen değişkenleri alarak model daha büyük bir hale getirilir.

Adım adım seçme

Bu metotta ilk olarak bağımsız değişkenler seçilir. Seçimler yüksek korelasyondan düşük korelasyona doğru yapılır. İstenilen ölçütlere uygun bağımsız değişkenlerle regresyon analizine başlanır.

3.2.2. Bulanık mantık

1900'lü yıllarda Aristo mantığına ek olarak Jan Lukasiewicz üçüncü bir değer daha eklemiş ve bunu $[0,1,2]$ olarak göstermiştir. Lukasiewicz'in aksine Donald E. Knuth $[-1,0,1]$ sayılarını kullanmıştır. Bu dönemde üç değerli yöntemler kabul görmemiştir. Modern anlamda bulanık mantığın kurucusu Zadeh olmuştur. Zadeh bulanık mantık ile ilgili çok fazla yayın yapmış ve bulanık mantığın önderi olmuştur.

Bulanık mantık ilk olarak 1975 tarihinde Assilian ve Mamdani tarafından buhar makinelerinin kontrol sisteminde kullanılmıştır. Hitachi alı firma 1987’de Sendai metrosunun yapımında bulanık mantığı kullanmışlardır ve %10 enerji tasarrufu elde etmişlerdir. Enerji tasarrufunun yanı sıra metronun gereken yerde durması üç kat daha iyi hale getirilmiştir. Tokyo borsasında kara pazar olarak bilinen 1988 yılında krizin belirtileri ana konusunda bulanık mantık olan bir sistem tarafından on sekiz gün önceden bilinmiştir. Bu çalışmalarla birlikte bulanık mantığa ilgi iyice artmıştır. İlginin artmasıyla 1989’da IBM, Toshiba, Thomson, Matsuhita gibi birçok firma birlikte Laboratory For Interchange Fuzzy Engineering (LIFE) adlı bir laboratuvar kurmuşlardır (Keskenler,2017).

1970’lerden sonra Japonya da teknolojik gelişmelerde bulanık mantığın kullanılması bulanık mantığın önemini iyice arttırmıştır. Batıya göre Türk dünyasında ve Japonya da bulanık mantık daha çok benimsenmiştir. Bunun nedeni olarak doğu dünyasının felsefi düşünce yapısı ile bulanık mantıktaki geçiş ve sürekliliğin uygun olmasıdır. Klasik mantıkta 0 veya 1 vardır. Yani ya vardır ya da yoktur. Fakat bulanık mantık bize var ya da yokun dışında olabilir gibi farklı ifadelerinde olduğunu göstermektedir.

Bulanık mantık ile Klasik (Aristo) mantığının arasındaki temel farklar Çizelge 3.2’de gösterilmiştir.

Çizelge 3.2. Klasik Mantık ile Bulanık Mantık arasındaki farklar

Klasik (Aristo) Mantık	Bulanık Mantık
A veya A değil	A ve A değil
Kesin	Kısmen
Hepsi veya Hiçbiri	Derecelendirilmiş
İkili birimler	Bulanık Birimler
0 veya 1	0 ve 1 arasında süreklilik

Zadeh Bulanık Mantığın genel özelliklerini şu şekilde sıralamıştır (Keskenler, 2017);

- 1) Bulanık mantıkta yaklaşık değerlere sahip bir düşünce sistemi kullanılır. Kesin nedenlere bağlı düşünce sistemi değildir.
- 2) Bulanık mantıkta her şey bir derece ile gösterilir. Bu dereceler 0 ile 1 aralığındadır.
- 3) Bulanık mantıkta sözel ifadeler kullanılır. Az, çok, çok az gibi.
- 4) Bulanık mantıkta kurallar sözel ifadelerle tanımlanır.
- 5) Bütün mantıksal sistemler bulanık olarak kabul edilebilir.
- 6) Matematiksel modeli çok zor oluşturulan sistemler için bulanık mantık oldukça uygundur.

Zadeh sıraladığı bu özelliklerle dilin bulanık yapısını vurgulamak istemiştir. İki değerli mantığın hareketi ve düşünceyi kısıtlamalarından kurtulmayı sağlayan bulanık mantığı kesin doğru veya kesin yanlış arasında sonsuz değerlerin olduğunu bulanık mantık ile açıklamıştır. Bulanık mantıkta klasik mantığın aksine aynı anda hem doğru hem de yanlış olduğunu ifade etmek mümkündür. Çünkü bulanık mantıkta kesinlik yani kesin doğru veya kesin yanlış yoktur, doğruluğun bir çok değeri vardır. Bulanıklık belirsizlikten kaynaklanmaktadır.

Bulanık mantığın avantajları şunlardır;

- 1) Herhangi bir matematiksel model gerektirmez.
- 2) Bir çok giriş ve çıkış değerleri aynı anda ele alınabilir.
- 3) Bulanık mantıkta bütün kurallar aynı anda uygulanır ve aynı anda sonuç alınır. Uyuşmayan kurallar uydurulabilir.
- 4) Giriş ve çıkış değerlerinin birleşimleri için çıkış belirleme zorunluluğu yoktur.
- 5) İstenilen çıktı elde edilmezse kurallar yeniden düzenlenebilir.
- 6) İstenilen kurallar rahatlıkla eklenebilir.
- 7) Karmaşık sistemlerde birden fazla bulanık denetleyici kullanılabilir.
- 8) Bulanık mantığın işleyiş sistemi insan düşüncesiyle büyük ölçüde benzerlik gösterir.
- 9) Doğrusal olmayan sistemlerde bulanık mantık iyi sonuç verir.
- 10) Eksik tanımlamalar olsa dahi bulanık mantık sonuca varmak için uygundur.


Bulanık mantığın dezavantajları şunlardır;

- 1) Bulanık mantık kurallarının oluşturulması kişilere bağlıdır. Bu da kişinin bilgi birikimleriyle, düşünceleriyle ve tecrübeleriyle doğrudan bağlantılıdır.
- 2) Üyelik fonksiyonlarının bulunması deneme yanılma yoluyla belirlenir. Genel bir kuralı yoktur. Bu nedenle çok fazla zaman kaybına sebep olabilir.
- 3) Kuralları tanımlamak her zaman kolay değildir. Uzun zaman alabilir.

3.2.2.1. Bulanık küme kavramı


Bulanık kümeler bulanık sistemlerin en temel elemanıdır. Bulanık kümelerde farklı üyelik derecelerine sahip elemanlar vardır. Zadeh bulanıklığının derecelendirmeye alakalı olduğunu savunmuştur. Bu kümelerde elemanlar 0 ile 1 arasında üyelik derecelerine sahiptirler. Geleneksel küme teorisi iki seçenekli mantığa dayanır. Yani ya kümenin elemanıdır ya da değildir. Bulanık küme kavramıysa iki değerli üyeliği çok değerliliğe taşır. 0 derecesi bulanık kümeye dahil olmayan elemanın üyelik derecesi iken, bulanık kümeye tam dahil olan elemanın üyelik derecesi 1'dir. Bulanık kümeye dahil olup olmadığı bilinmeyen elemanlar durumuna göre 0 ile 1 arasında değerler alır.

Şekil 3.8 de yaşlı insanlar için bulanık ve kesin kümeler verilmiştir. Kesin kümede yaşlılığı siyah renk, bulanık kümede yaşlılığın düzeyini siyah rengin tonu belirlemektedir. Şekil 3.8 a da kesin kümede 60'dan küçük olanlar yaşlı sayılmazken 60 ve üzeri olanlar yaşlı sayılırlar. Oysa şekil 3.8b de yani bulanık kümede sadece yaş 75 ve üzeri olanlar yaşlı değil 25 ve 75 arasında olanlarda yaşlı kümesine dahildir.

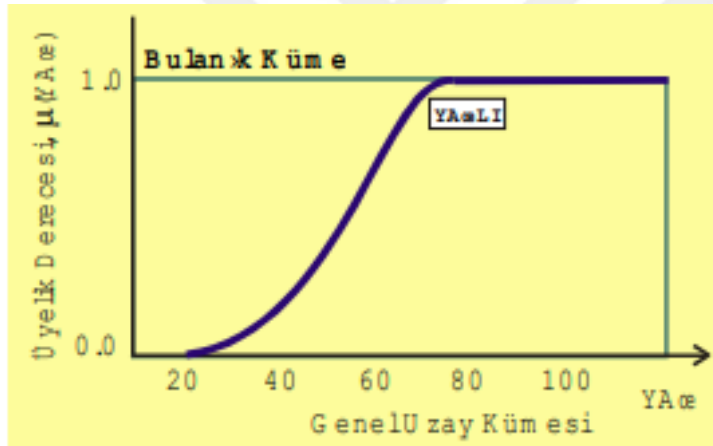


Şekil 3.8. Yaşlılar kümesinin kesin ve bulanık küme ile gösterimi (Altaş,1999)

Şekil 3.8a ve b bulanık ve kesin kümeler Şekil 3.9 ve Şekil 3.10'daki gibi de üyelik fonksiyonları ile gösterilebilir.




Şekil 3.9. Yaşlı kesin kümesi (Altaş,1999)



Şekil 3.10. Yaşlı bulanık kümesi (Altaş,1999)

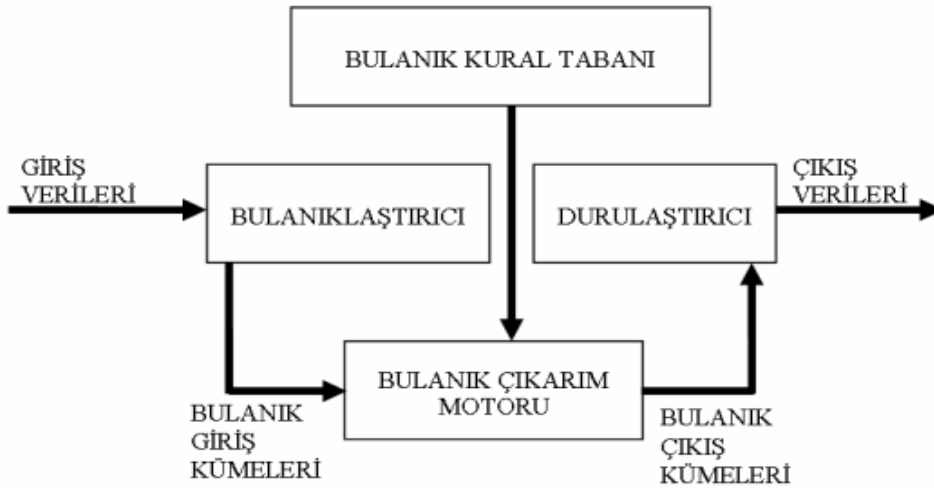
Başka bir bulanık küme örneği verecek olursak 15 °C sıcaklığı normal bir sıcaklık kabul edersek klasik küme kuramına göre 15 °C üzerindeki sıcaklıkları sıcak olarak kabul ederiz ve bu derecelerin sıcak kümesindeki üyelik dereceleri '1' olur. Sıcaklık 15 °C'nin altında ise soğuktur. Soğuk kümesindeki üyelik dereceleri '0' olur. Soğuk kümesini temel alırsak bu değerler tersine döner. Bulanık küme yaklaşımında ise üyelik değerleri [0,1] aralığında değerler almaktadır. Örneğin 13 °C sıcaklık için üyelik derecesi '0', 15 °C derecesıcaklık için üyelik derecesi '0,45' olabilir. Bulanık mantığın örnekleme Şekil 3.11'de verilmiştir.



Şekil 3.11. Bulanık mantık örnekleme (Wikipedia, 2021)

3.2.2.2. Bulanık çıkarım sistemleri

Bulanık sistemler bulanık küme ilkelerini kullanan girdi değişkenlerinden çıktı değişkenlerini elde etmek amacıyla kurulan sistemlerdir. Bulanık sistemlerde sözel ifadelerin kullanılması çözüme ulaşmada büyük avantaj sağlar. Bulanık çıkarım sistemleri Eğer – İse kurallarına dayanan sistemlerdir. Bulanık sistemler girdi ve çıktılardan oluşmaktadır. Bulanık sistemin kısaca özeti Şekil 3.12 ‘de verilmiştir.



Şekil 3.12. Bulanıklaştırma – Durulaştırma birimi bulanık sistem

Genel bilgi tabanı birimi

Ele alınan olayı etkileyen girdi verilerini ve bu veriler hakkında ki bütün bilgileri sayısal veya sözel olarak içeren kısımdır.

Bulanıklaştırma

Bulanık mantık ile modellemenin ilk adımıdır. Kesin değerler bulanık değerlere dönüştürülür. Üyelik derecelerinin atandığı işlemcidir. Sayısal veriler sözel verilere dönüştürülür. Şekil 3.13 de veri kümelerinin bulanıklaştırılması gösterilmektedir.

Bulanık kural tabanı birimi

Eğer ve ise olarak yazılabilen giriş verilerini çıkış verilerine bağlayan kısmı içerir. Kurallar yazılırken girdi ve çıktı verileri arasındaki bütün bağlantıların kuralları oluşturulur. Girdi ve çıktıların hepsinin birbirine bağlanması kural tabanını oluşturur.

Bulanık çıkarım motoru birimi

Bulanık kural tabanındaki bütün giriş ve çıkış ilişkilerini bir araya toplayarak bir çıkışlı davranmasını sağlar. Girdilerin nasıl bir çıktı vereceğini belirler.

Durulaştırıcı

Bulanık çıkarım sonuçlarını sayısal çıktılara dönüştürür.

Çıktı birimi

Bilgi ve bulanık kural tabanlarının etkileşimlerinin sonucunda ki çıktı değerlerin bulunduğu topluluktur.

3.2.2.3. Mamdani bulanık çıkarım sistemi

En fazla uygulanan ve kullanılan bulanık mantık sistemlerinden biride mamdani bulanık çıkarım sistemidir. En çok kullanılan bulanık çıkarım yönteminin olmasının sebepleri; tasarımının kolay olması, insan davranışlarına uygun olması ve daha çok yorumlanabilir olmasından dolayıdır. İbrahim Mamdani (1977) bulanık mantığın ilkerini temel alarak mamdani yöntemini geliştirmişti. Mamdani bulanık çıkarım yöntemi bulanık mantık modellerinin temelini oluşturur. İlk kez bir buhar motorunun insan tecrübelerinden. Bilgi ve birikimlerinden elde edilen sözel kurallar yardımıyla kontrolü amacıyla kullanılmıştır (Mamdani ve Assilian, 1975). Mamdani bulanık çıkarım sisteminde girdi ve çıktılar üyelik fonksiyonlarıyla ifade edilir.


Mamdani tipi bir bulanık mantık modeli oluştururken 5 adım izlenir.

- Bulanık ifadeler kullanılarak girdi değişkenlerine 0 ile 1 arasında üyelik derecelerinin belirlenmesi
- Kuralların belirlenmesi
- Ve, veya uygulaması
- Çıktıları temsil eden bulanık kümelerin birleştirilmesi
- Bulanık küme sonuçlarının durulaştırılması

Şekil 3.13'de x veya y gibi sayısal değişken içeren iki kurallı mamdani tipi bulanık çıkarım sisteminde c_i bulanık küme fonksiyonlarının nasıl hesaplandığı gösterilmektedir.

$$\text{Kural 1 : eğer } x = A_1 \text{ VE } y = B_1 \text{ ise } z = C_1 \quad (3.3)$$

$$\text{Kural 2 : eğer } x = A_2 \text{ VE } y = B_2 \text{ ise } z = C_2 \quad (3.4)$$



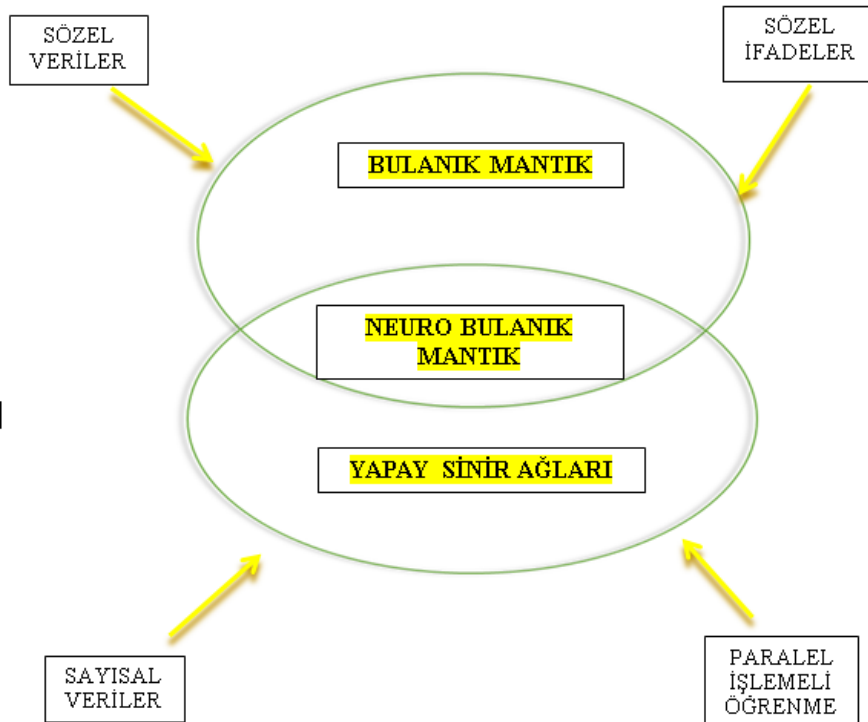
Şekil 3.13. Bulanık ve ve veya işlemleri için sırasıyla minimizasyon ve maksimizasyon operatörlerini kullanan mamdani tipi bulanık çıkarım sistemi (Akyılmaz, 2005)

Mamdani tipi bulanık modelin avantajları şunlardır:

- Mamdani tipi bulanık modelin oluşturulması basittir.
- Mamdani tipi diğer bulanık mantık modellemelerin temelini oluşturur.
- Mamdani tipi bulanık model insan davranış ve duygularına uygundur.

3.2.2.4. Uyarlamalı ağ tabanlı bulanık çıkarım sistemi (ANFIS)

ANFIS kelimesi Adaptive Neuro-Fuzzy Inference System'in baş harflerinden oluşmaktadır. ANFIS bir yapay sinir ağı yöntemidir. Takagi-Sugeno bulanık çıkarım sistemine dayalıdır. Doğrusal olmayan fonksiyonların modellenmesi için 1990'ların başlarında Jang tarafından geliştirilmiştir. ANFIS, bulanık çıkarım yöntemlerinin ve sinir ağları yöntemlerinin her ikisinden de faydalanır. ANFIS modelinin gelişmesinde mevcut sistemlerdeki bilgi girişi yetersizliği ve anlaşılmada yaşanan zorluklar etkili olmuştur. Sinir ağlarında öğrenilen bilgiyi anlamak zordur. Bulanık mantıktaki anlaşılabilir sözel ifadeler sinir ağları ile öğrenilen bilgiyi anlamayı kolaylaştırır. Bu şekilde sistem ve insan arasındaki bilgi akışı daha anlaşılır ve kolay olur. Sözel terimler ve eğer-ise kuralları anlaşılmaya yardımcı olur.



Şekil 3.14. Sinirsel – Bulanık sistemlerin sinir ağları ve bulanık mantık ile ilişkisi (Tortum, 2003)

3.2.3. Destek vektör makineleri (DVM)

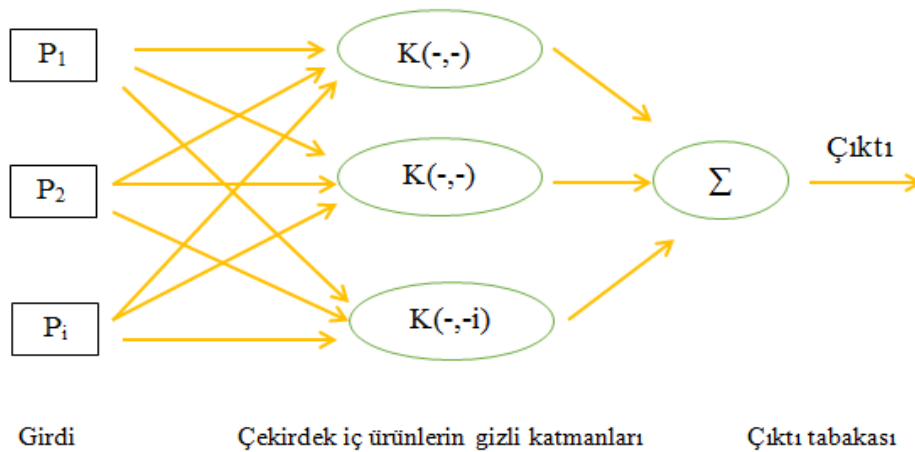
DVM vektör uzayı tabanlı makine öğrenme yöntemi olarak tanımlanabilir. Destek vektör makineleri regresyon tipi problem çözümlenmeleri için 1995 yılında ilk kez Vapnik tarafından önerilmiştir. Destek vektör makineleri ilke olarak yapısal riski en aza indirme ve istatistiksel

öğrenme teorisine dayanır. Destek vektör makineleri yerel çözümlemelere takılmadan regresyon veya sınıflandırma problemini, karesel programlama problemine dönüştürerek çözer. Destek vektör makinelerinin diğer tekniklere göre avantajlı olmasının sebeplerinden biride yerel çözümlemelere takılmama özelliğidir. DVM'nin başka bir özelliği de genelleme yapabilmesidir. Destek vektör makinelerinin farklı uygulama alanları vardır. Yüz tanıma, el yazısı tanıma, bankacılık, tıp, sigorta ses tanıma, metin sınıflandırma, 3 boyutlu nesne tanıma, konuşmacı tanıma gibi uygulamalar örnek olarak verilebilir.

Son zamanlarda destek vektör makineleri su kaynakları alanında da kullanılmaya başlanmıştır. YSA ve diğer modellerle karşılaştırıldığında DVM'ler daha iyi performans göstermişlerdir. Genel olarak pratikte destek vektör makineleri başarılı sonuçlar vermektedir.

Destek vektör makinelerini daha etkili bir biçimde kullanmak için sistemlerini de iyi bilmek gerekir. Destek vektör makinesi eğitilirken doğru kararlar vermek önemlidir. Bu kararları verirken kullanıcının bilgi birikimi ve tecrübesi önemlidir. İlk olarak veri nasıl işlenmeli, hangi çekirdek fonksiyonu kullanılmalı ve hangi parametrelere öncelik verilmeli bu gibi sorulara karar verilmelidir. Seçimler ne kadar doğru olursa başarı da o kadar yüksek olur.

Şekil 3.15'de polinom çekirdek fonksiyonlu destek vektör makinesine ait şematik gösterim verilmiştir.




Şekil 3.15. DVM'nin şematik gösterimi

Destek vektör makineleri girdi katmanı, çekirdek iç ürünlerin gizli katmanları ve çıktıdan oluşmaktadır. Destek vektör makineleri, doğrusal ve doğrusal olmayan olarak 2 farklı grupta incelenir.

Şekil 3.16'da destek vektör makinelerinin temel yapısı gösterilmektedir. Sistemin temel amacı noktaları maksimum marginle ayıran hiperdüzlem oluşturabilmektir. Bunun için de noktalar pozitif ve negatif tanımlanır. Örnek olarak şu formatta bir eğitim kümesi olsun:

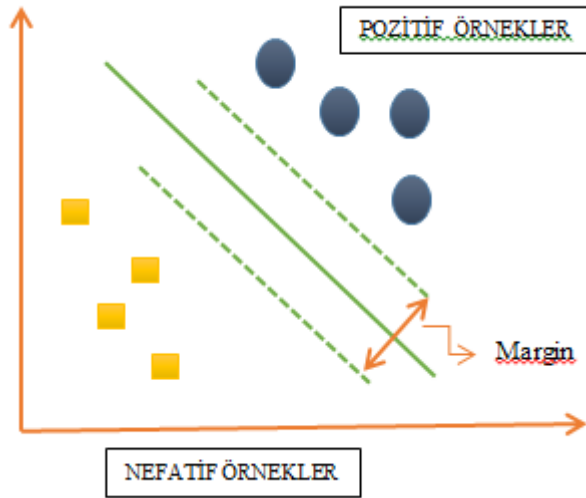
$$(x_1, y_1), \dots, (x_n, y_n) \quad (3.5)$$

x_i hiper düzlemdeki noktayı ifade eder. y_i ise noktanın hangi kümeye ait olduğunu gösterir. $y_i + 1$ veya -1 değerini alır. Şekil 3.16'da iki boyutlu veri kümesinde sarı kareler $y_i = -1$ 'i, lacivert yuvalaklar $y_i = +1$ değerini gösterirler.



Şekil 3.16. 2 boyutlu uzayda örnek veri kümesi

Veriler negatif ve pozitif olarak ayrıldıktan sonra sonsuz hiper düzlem oluşturulabilir. En uygun ayırıcı düzlem margin'in maksimum olduğu yerdir. Burada söylenen margin terimi ayırıcı düzlemden en yakın veri noktasına olan minimum uzaklığı belirtir. Şekil 3.17'de bu ayrımına örnek gösterilmiştir.



Şekil 3.17. İki veri kümesini ayıran hiper düzlem örneği

Sınıflandırmadaki asıl amaç gelecek olan verinin hangi tarafta yer alacağına karar vermektir. Sınıflandırma yapmak için sınıfları birbirinden ayıran bir doğru çizilir. Çizilen doğrunun -1 ve +1 arasındaki kısmına margin adı verilir. Sınıflar ne kadar iyi ayrılmışsa margin de o kadar geniştir.

Doğrusal destek vektör makineleri iki grupta incelenir. Sert marginli ve esnek marginli olarak ayrılır.

Margini maksimum yapabilmek için w değerini minimum yapmak gerekir. Bu durumda 2 temel kısıtlama vardır. Bunlar için denklemler şu şekildedir:

$$y_i = +1 \text{ için } w * x_i + b \geq +1 \quad (3.6)$$

$$y_i = -1 \text{ için } w * x_i - b \leq -1 \quad (3.7)$$

Denklemden ki w hiper düzlem normalini, x düzlemin yerini ve b bias terimini ifade eder.

Denklemlerini tek bir denklem haline getirmek istersek;

$$y_i (w * x_i + b) \geq +1, \forall_i, \min_{w,b} ||w|| \quad (3.8)$$

b biası eğilim değerini yani hiper düzlemin orijinden olan uzaklığıdır.

Destek vektör makinesi eğitildikten sonra yeni bir x_c verisi ortaya çıkar. x_c 'nin hangi sınıfa ait olduğu şu fonksiyonla ifade edilir:


$$x_c \longrightarrow \text{sgn}(wx_c+b)$$

Burada (wx_c+b) 'nin sonucu negatifse -1, (wx_c+b) 'nin sonucu pozitifse +1 grubuna yazılır.


Araştırmacılar ilk başlarda doğrusal sınıflandırma çalışmaları yapmışlardır. İleriki zamanlarda destek vektör makineleriyle birlikte çekirdek fonksiyonlarını kullanarak doğrusal olmayan sınıflandırma yöntemini de geliştirmişlerdir.

Destek vektör makineleri doğrusal olmayan bir veri kümesinden doğrusal bir hiper düzlem çizemedikleri için doğrusal sınıflandırma bazı problemlerde yeterli gelmeyebilir. Çok boyutlu problemlerde hiper düzlem veri dağılımı doğrusal olmadığı için doğrusal bir yapıya sahip değildirler. Bu tür durumlarda çekirdek fonksiyonları kullanılır. Çekirdek fonksiyonları da doğrusal olmayan hiper düzlem oluşturmayı kolaylaştırır.

Şekil 3.18 ve Şekil 3.19'de çekirdek fonksiyonunu kullanarak doğrusal olmayan girdi uzayında haritalama işlemini göstermektedir. Burada amaç doğrusal olarak tanımlanamayan girdi uzayındaki verilerin çekirdek fonksiyonu ile haritalanarak doğrusal olarak sınıflandırılmasıdır.



Şekil 3.18. Doğrusal olarak sınıflandırılmayan DVM gösterimi



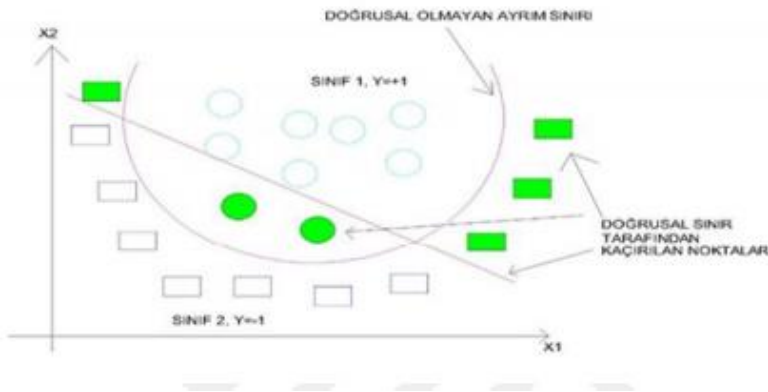
Şekil 3.19. Doğrusal olarak sınıflandırılmayan girdi uzayının bir üst boyuta çekirdek fonksiyonu ile haritalanması

Polinom çekirdek fonksiyonu


En basit çekirdek fonksiyonudur. Bir c sabiti ile belirtilir. Polinom çekirdek fonksiyonunun formülü şu şekildedir.

$$k(x,y) = (x^T \cdot y + c)^d \quad (3.9)$$

formülde c sabit terim ve d polinom derecesi olarak kullanılır.



Şekil 3.20. Polinom çekirdek gösterimi (Karaeminoğulları, 2020)



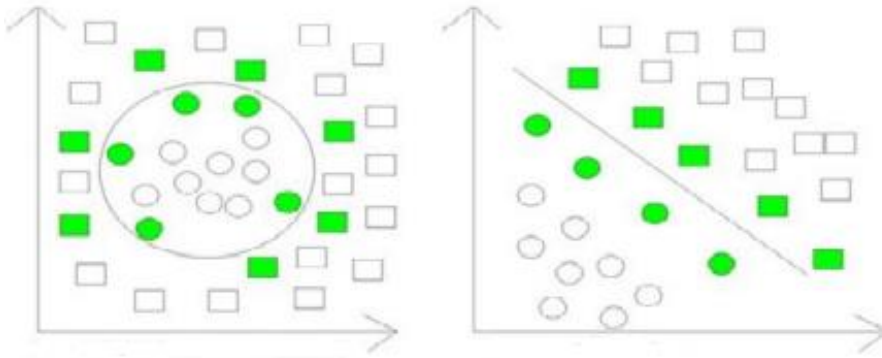
Şekil 3.21. Doğrusal olmayan 2 boyutlu örnek uzay gösterimi (Karaeminoğulları, 2020)

Radyal tabanlı çekirdek fonksiyonu

Radyal tabanlı sınıflandırma, örneği yüksek boyutlu uzaya taşıyarak gerçekleştirir. Diğer çekirdek fonksiyonlarından biraz farklıdır. Daha sıkıştırılmış bir çekirdektir. Bu özelliği eğitim sürecini biraz kısıtlar. Bu yüzden genelleştirme verimliliğini iyileştirmeyi uygun hale getirir. Radyal tabanlı çekirdek fonksiyonunun denklem gösterimi şu şekildedir.

$$k(x,y) = e^{-\gamma ||(x-x_1)^2 ||} \quad (3.10)$$

Şekil 3.22’de radyal tabanlı çekirdek fonksiyonuna ait haritalama şekli gösterilmiştir.



a) Radyal tabanlı fonksiyon

b) Haritalama

Şekil 3.22. Radyal tabanlı fonksiyona ait çekirdek fonksiyonu

4. ARAŞTIRMA BULGULARI ve TARTIŞMA

Bu bölümde, nehirde akış miktarı tahmin edilmeye çalışılmıştır. Nehirde akış miktarı ÇDR, bulanık mantık ve DVM kullanılarak sonuçlar değerlendirilmiştir. Ortalama sıcaklık ($T_{ort.}$), yağış (P), debi zaman serisi (T-1) ve debi (m^3/s) modellerin karşılaştırılmasında istatistik parametre olarak kullanılmıştır. Ortalama sıcaklık ($T_{ort.}$), yağış (P), debi zaman serisi (T-1) girdi parametreleri, debi (m^3/s) ise çıktı parametresidir. Sonuçlar, modelin tahmini ve gözlem verilerinin performanslarını karşılaştırmak için kullanılmıştır. Çalışmada kullanılan karşılaştırma parametreleri ile ilgili kısaca bilgiler verilecek olup, diğer kısımda modellemelere ait sonuçlar grafiklerle gösterilip karşılaştırmaları ve yorumları yapılmıştır.

4.1. Model Performansında Kullanılan İstatistiksel Parametreler

Bu çalışmada, 1095 günlük ortalama sıcaklık, yağış ve debi verilerinin 820 tanesi yani %75'i eğitim, geriye kalan 275 veri yani %25'i test için kullanılmıştır. Modellemelerde R, ortalama mutlak hata (MOH) ve karesel hataların ortalamasının karekökü (KKOH) kriterlerine göre değerlendirilip çıkan sonuçlar yorumlanmıştır.

Korelasyon katsayısı (R)

Korelasyon analizi bir istatistiksel yöntemdir. x ve y değişkenleri arasındaki ilişkinin derecesini ve önemini belirtir. İlişkinin derecesini belirten bu katsayıya da korelasyon katsayısı denir. R sıfıra ne kadar yakınsa değişkenler arasında bir ilişkinin olmadığı eğer 1'e yakın değerler alıyorsa değişkenler arasında bir ilişkinin olduğu, en uygun olanının olduğu yorumları yapılır. R'nin denklemi Denklem 4.1'deki gibidir.

$$R = \sqrt{\frac{n\sum xy - (\sum x)(\sum y)}{(\sqrt{(n\sum x^2) - (\sum x)^2})\sqrt{(n\sum y^2) - (\sum y)^2)}}} \quad (4.1)$$

Mutlak ortalama hata (MOH)

MOH tahmin edilen değer ile gerçek değer arasındaki değişkenlerin tahminindeki hataların ortalama büyüklüğünü ölçer. Bu ifadeler sıfırdan sonsuza kadar değer alabilir ve değer ne kadar küçükse o kadar kullanışlıdır. Denklem 4.2'deki gibidir.

$$MOH = \frac{1}{N} \sum_{i=1}^N |Q_{ölçüm} - Q_{tahmin}| \quad (4.2)$$

Yukarıdaki denklemde Q akış miktarını, N ise veri sayısını temsil etmektedir.

Karesel hataların ortalama karekökü (KKOH)

KKOH hataların ortalama büyüklüğünü ölçer. Bu ifadeler MOH'da ki gibi sıfırdan sonsuza kadar gidebilir ve değer ne kadar küçükse model gerçek değere o kadar yakındır. Denklem 4.3'de ki gibidir.

$$KKOH = \sqrt{\frac{1}{N} \sum_{i=1}^N (Q_{ölçüm} - Q_{tahmin})^2} \quad (4.3)$$

Yukarıdaki denklemde Q akış miktarını, N ise veri sayısını ifade eder.

Sonuçlar, tahmin ve performans açısından karşılaştırmak için kullanılacaktır.

4.2. Model Sonuçları

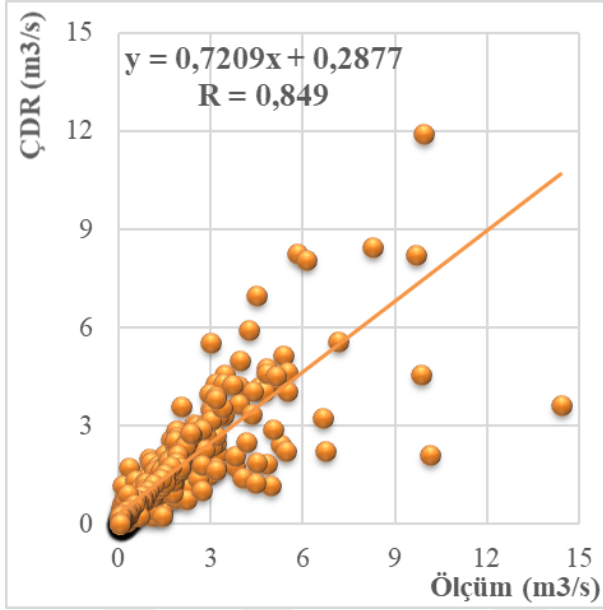
Çalışmada ÇDR, DVM ve bulanık mantık modellerinin sonuçları incelenmiş ve yorumlanmıştır. Bu modellere ait sonuçlar aşağıda verilmiştir.

4.2.1. ÇDR model sonuçları

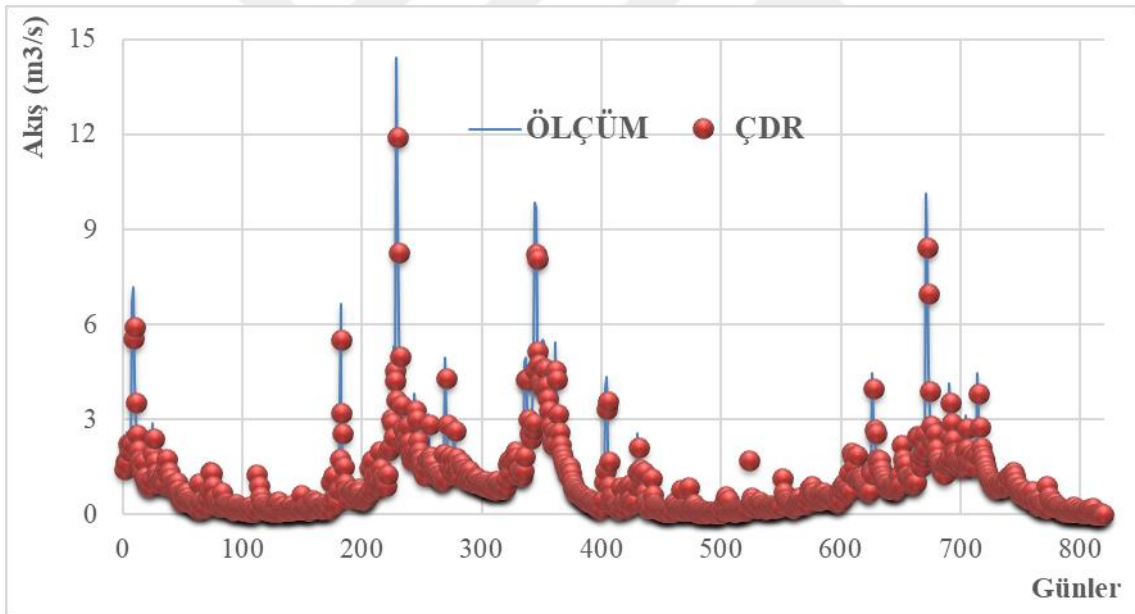
ÇDR modeli için 2014-2017 yılları arası 3 yıllık toplamda 1095 tane verinin %75'i yani 820 tanesi eğitim, kalan %25'i yani 275 tanesi test için değerlendirilmiş ve sonuçlar aşağıdaki grafiklerle gösterilmiştir.

ÇDR modelinde ortalama sıcaklık (T_{ort}), yağış (P) ve debi zaman serisi (T-1) girdi olarak, debi (m^3/s) miktarı çıktı olarak alınmıştır.

Şekil 4.1 ve Şekil 4.2'de ÇDR modeli eğitim verileri için dağılım ve saçılım grafikleri verilmiştir.




Şekil 4.1. Günlük akış miktarı eğitim verileri için ÇDR yöntemine ait saçılım grafiği

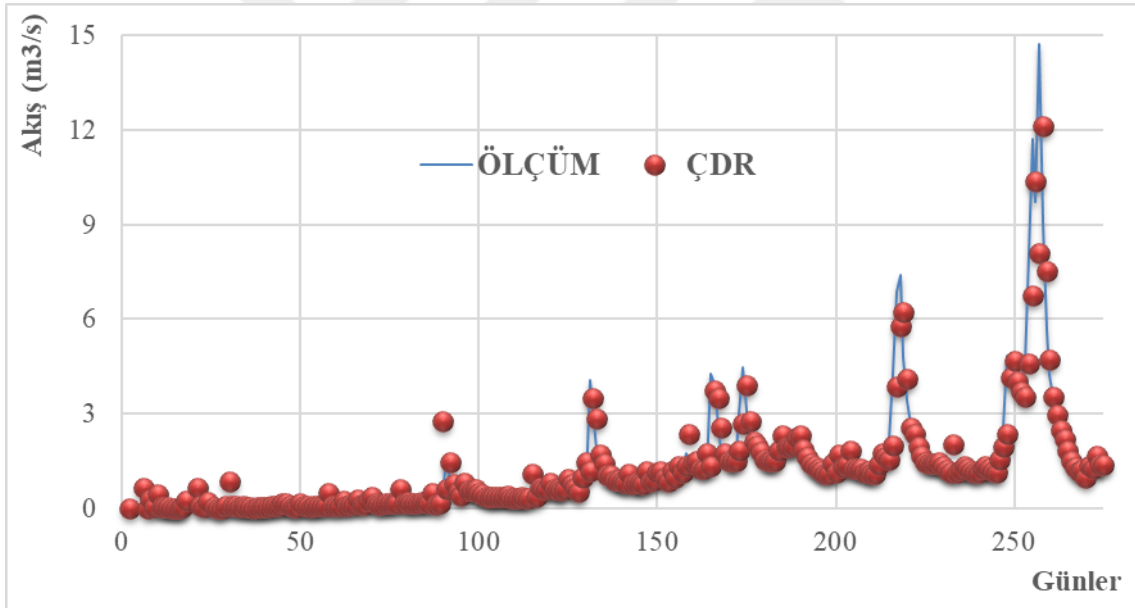


Şekil 4.2. Günlük akış miktarı eğitim verileri için ÇDR yöntemine ait ölçüm ve dağılım grafiği

Şekil 4.1 ve Şekil 4.2 incelendiğinde ölçüm ve model arasındaki R 0,849 olduğu tespit edilmiştir. Çoklu doğrusal regresyon modeli eğitim verilerinin analizi ile elde edilen, ÇDR modeli test verileri dağılım ve saçılım grafikleri Şekil 4.3 ve Şekil 4.4'te verilmiştir.



Şekil 4.3. Günlük akış miktarı test verileri için ÇDR yöntemine ait saçılım grafiği



Şekil 4.4. Günlük akış miktarı test verileri için ÇDR yöntemine ait ölçüm ve dağılım grafiği

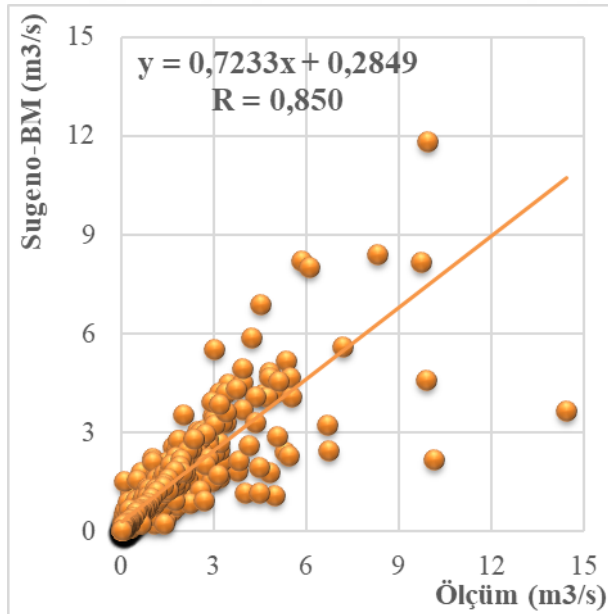
Test aşamasında, Şekil 4.3 ve Şekil 4.4'deki saçılım ve dağılım grafikleri incelendiğinde korelasyon katsayısı R: 0.902 olarak elde edilmiş ve tahmin edilen MLR değerlerinin gerçek değerlere yakın olduğu görülmüştür.

4.2.2. Sugeno-BM model sonuçları

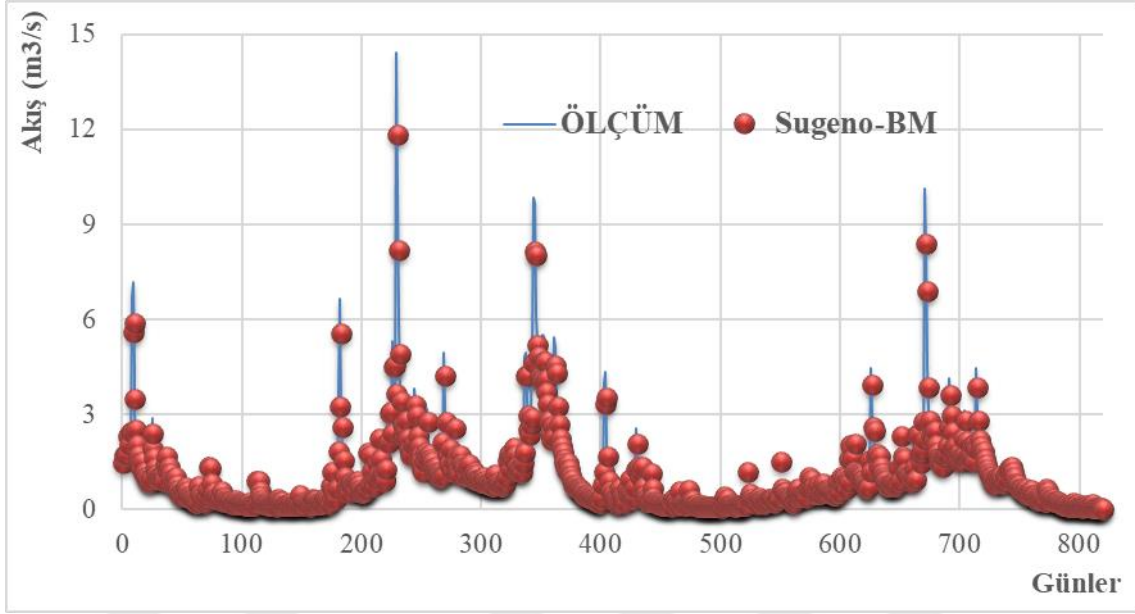
Sugeno-BM modeli için 2014-2017 yılları arası 3 yıllık toplamda 1095 tane verinin %75'i yani 820 tanesi eğitim, kalan %25'i yani 275 tanesi test için değerlendirilmiş ve sonuçlar aşağıdaki grafiklerle gösterilmiştir.

Sugeno-BM modelinde ortalama sıcaklık (T_{ort}), yağış (P) ve debi zaman serisi (T-1) girdi olarak, debi (m^3/s) miktarı çıktı olarak alınmıştır.

Şekil 4.5 ve Şekil 4.6'da Sugeno-BM modeli eğitim verileri için dağılım ve saçılım grafikleri verilmiştir.




Şekil 4.5. Günlük akış miktarı eğitim verileri için Sugeno-BM yöntemine ait saçılım grafiği

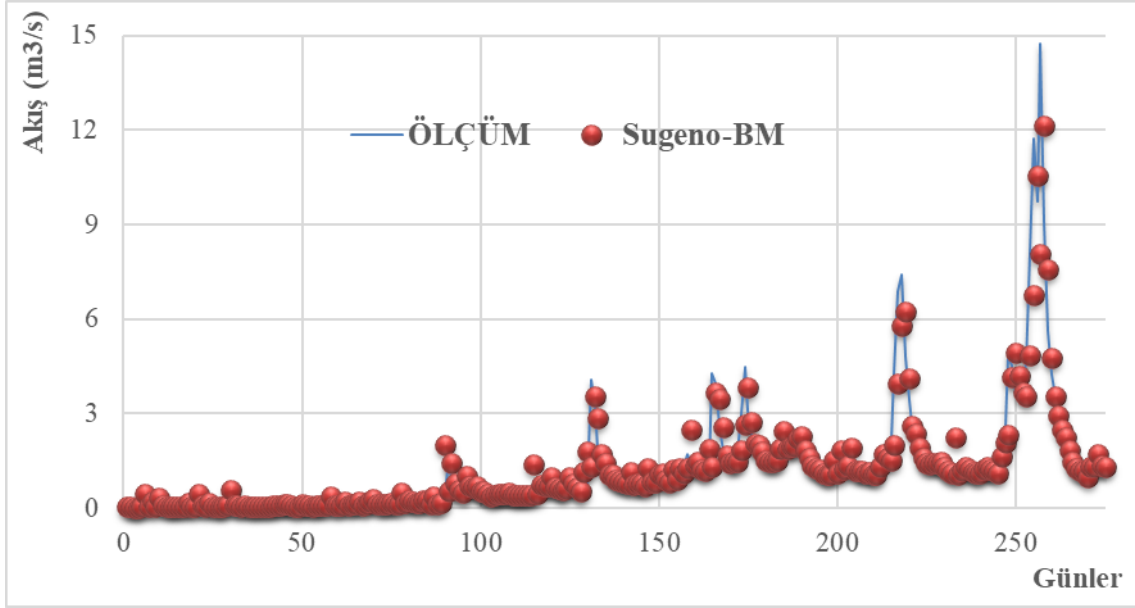


Şekil 4.6. Günlük akış miktarı eğitim verileri için Sugeno-BM yöntemine ait ölçüm ve dağılım grafiği

Şekil 4.5 ve Şekil 4.6 incelendiğinde ölçüm ve model arasındaki R 0,850 olduğu tespit edilmiştir. Sugeno-BM modeli eğitim verilerinin analizi ile elde edilen, Sugeno-BM modeli test verileri dağılım ve saçılım grafikleri Şekil 4.7 ve Şekil 4.8’de verilmiştir.



Şekil 4.7. Günlük akış miktarı test verileri için Sugeno-BM yöntemine ait saçılım grafiği



Şekil 4.8. Günlük akış miktarı test verileri için Sugeno-BM yöntemine ait ölçüm ve dağılım grafiği


Şekil 4.7'deki saçılım grafiği incelendiğinde korelasyon katsayısının 0.903 olduğu görülmüştür. Şekil 4.8' deki dağılım grafiği incelendiğinde diğer modellerde olduğu gibi ölçüm ve tahmin sonuçlarının birbirine benzer olduğu görülmüştür.

4.2.3. Mamdani-BM model sonuçları

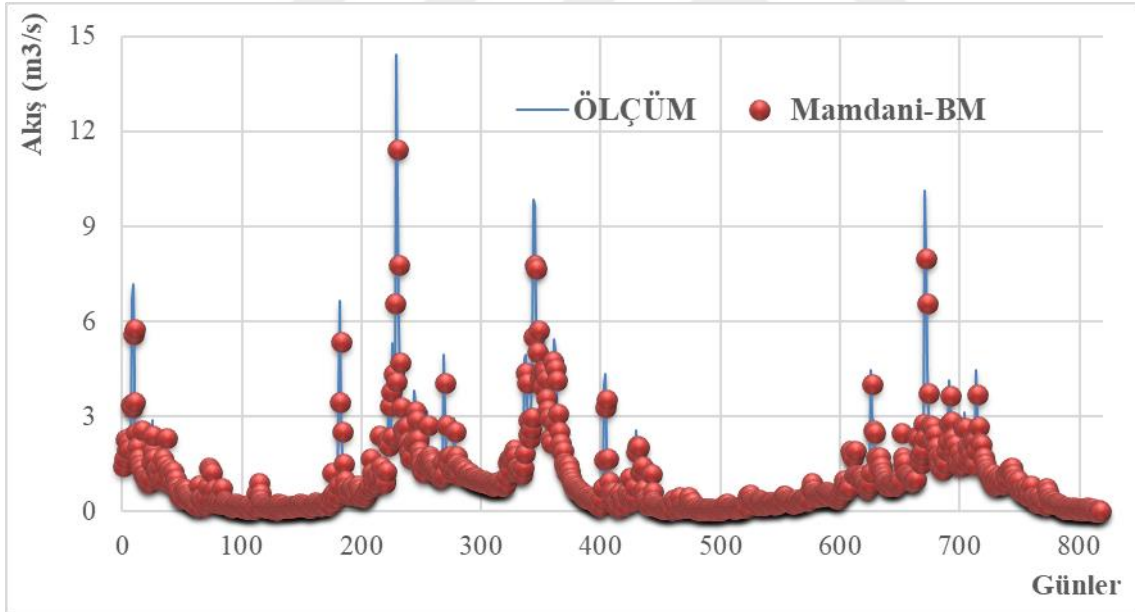
Mamdani-BM modeli için 2014-2017 yılları arası 3 yıllık toplamda 1095 tane verinin %75'i yani 820 tanesi eğitim, kalan %25'i yani 275 tanesi test için değerlendirilmiş ve sonuçlar aşağıdaki grafiklerle gösterilmiştir.

Mamdani-BM modelinde ortalama sıcaklık (T_{ort}), yağış (P) ve debi zaman serisi (T-1) girdi olarak, debi (m^3/s) miktarı çıktı olarak alınmıştır.

Şekil 4.9 ve Şekil 4.10'da Mamdani-BM modeli eğitim verileri için dağılım ve saçılım grafikleri verilmiştir.

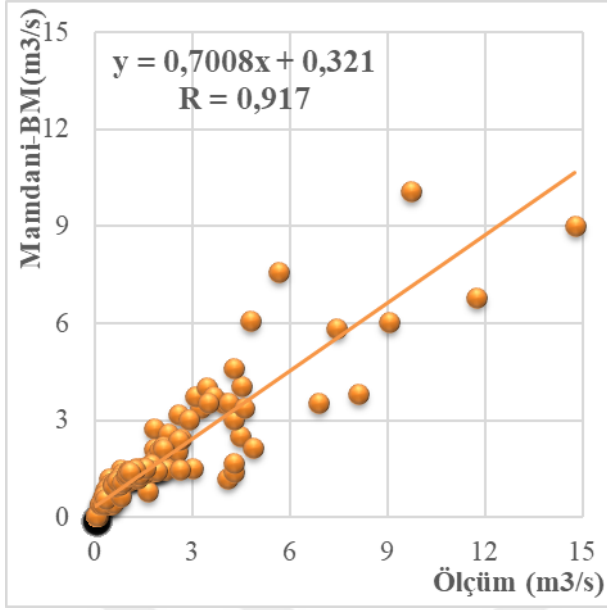


Şekil 4.9. Günlük akış miktarı eğitim verileri için Mamdani-BM yöntemine ait saçılım grafiği

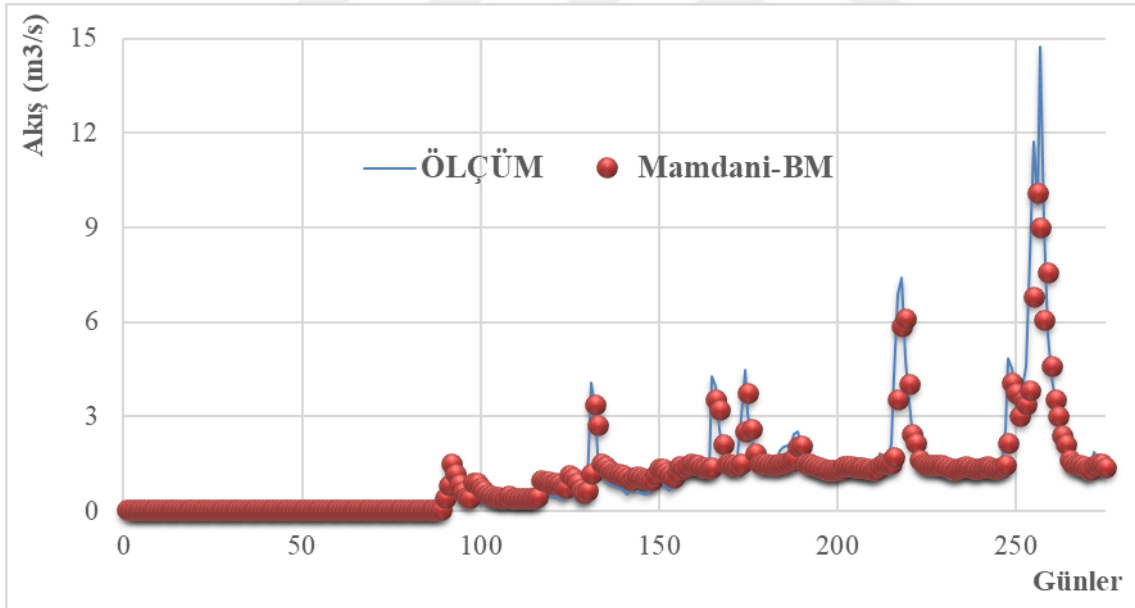


Şekil 4.10. Günlük akış miktarı eğitim verileri için Mamdani-BM yöntemine ait ölçüm ve dağılım grafiği

Şekil 4.9 ve Şekil 4.10 incelendiğinde ölçüm ve model arasındaki R 0,861 olduğu tespit edilmiştir. Mamdani-BM modeli eğitim verilerinin analizi ile elde edilen, Mamdani-BM modeli test verileri dağılım ve saçılım grafikleri Şekil 4.11 ve Şekil 4.12’de verilmiştir.



Şekil 4.11. Günlük akış miktarı test verileri için Mamdani-BM yöntemine ait saçılım grafiği



Şekil 4.12. Günlük akış miktarı test verileri için Mamdani-BM yöntemine ait ölçüm ve dağılım grafiği


Şekil 4.11 ve Şekil 4.12’de saçılım ve dağılım grafikleri incelendiğinde, ölçüm ve model arasındaki korelasyon katsayısı R: 0,917 olarak elde edilmiştir. Ölçüm ve model sonuçları arasında uyum olduğu görülmüştür.

4.2.4. DVM model sonuçları

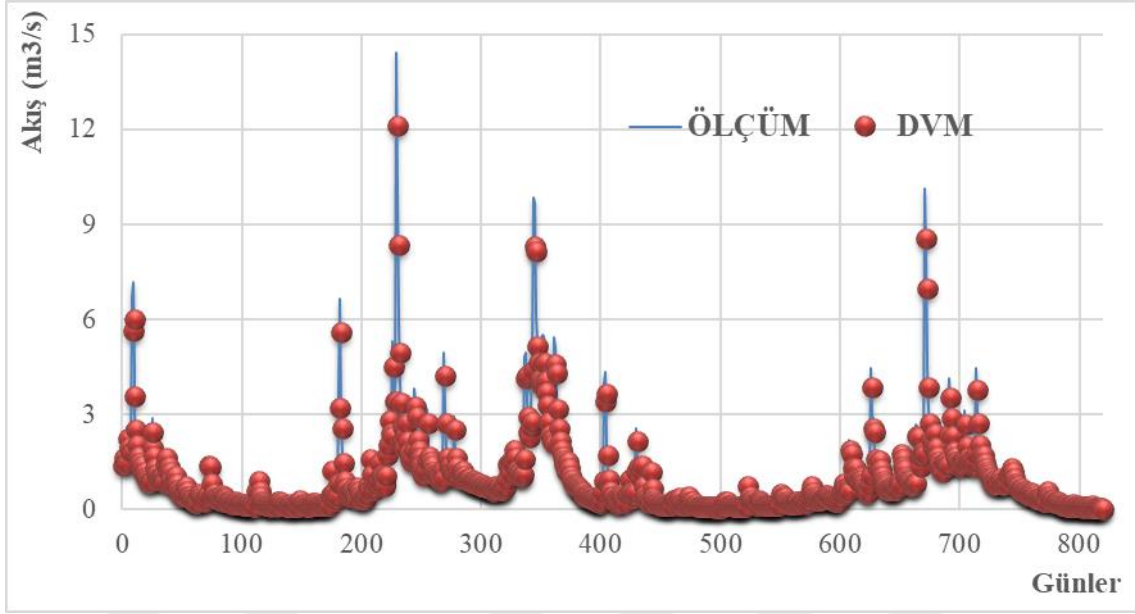
DVM modeli için 2014-2017 yılları arası 3 yıllık toplamda 1095 tane verinin %75'i yani 820 tanesi eğitim, kalan %25'i yani 275 tanesi test için değerlendirilmiş ve sonuçlar aşağıdaki grafiklerle gösterilmiştir.

DVM modelinde ortalama sıcaklık (T_{ort}), yağış (P) ve debi zaman serisi (T-1) girdi olarak, debi (m^3/s) miktarı çıktı olarak alınmıştır.

Şekil 4.13 ve Şekil 4.14'de DVM modeli eğitim verileri için dağılım ve saçılım grafikleri verilmiştir.




Şekil 4.13. Günlük akış miktarı eğitim verileri için DVM yöntemine ait saçılım grafiği




Şekil 4.14. Günlük akış miktarı eğitim verileri için DVM yöntemine ait ölçüm ve dağılım grafiği

Şekil 4.13 ve Şekil 4.14 incelendiğinde ölçüm ve model arasındaki R 0,843 olduğu tespit edilmiştir. DVM modeli eğitim verilerinin analizi ile elde edilen, DVM modeli test verileri dağılım ve saçılım grafikleri Şekil 4.15 ve Şekil 4.16'da verilmiştir.



Şekil 4.15. Günlük akış miktarı test verileri için DVM yöntemine ait saçılım grafiği



Şekil 4.16. Günlük akış miktarı test verileri için DVM yöntemine ait ölçüm ve dağılım grafiği

DVM model sonuçları için test aşamasındaki Şekil 4.15 ve Şekil 4.16'daki saçılım ve dağılım grafikleri incelendiğinde, ölçüm sonuçları ile tahmin sonuçları arasında iyi bir korelasyon olduğu görülmüştür. Yüksek korelasyon katsayısı R: 0.907 düşük hata oranları ile akış tahmininde iyi performans göstermiştir.

Çizelge 4.1. Günlük akış miktarı tahmininde kullanılan model sonuçlarının karşılaştırılması

Model İsimleri	Model Girdileri	MOH	KKOH	R
ÇDR	T, P, Qt-1	0,347	0,786	0,902
Sugeno-BM	T, P, Qt-1	0,345	0,782	0,903
Mamdani-BM	T, P, Qt-1	0,338	0,771	0,917
DVM	T, P, Qt-1	0,285	0,778	0,907

KKOH: Ortalama karesel hataların karekökü, **MOH:** Mutlak ortalama hata
R: Korelasyon katsayısı.

T_{ort}: ortalama sıcaklık, **P:** yağış, **T-1:** debi zaman serisi, **Q:** debi (m³/s)

Çizelge 4.1’de görüldüğü gibi, ÇDR modeli sonucunda MOH: 0,347- KKOH: 0,786- R: 0,902 olarak bulunmuştur. ÇDR modeli tahminleri diğer modeller arasında daha düşük performansı göstermiştir.

DVM modeli sonucunda MOH: 0,285- KKOH: 0,778- R: 0,907 olarak belirlenmiştir. ÇDR modelinde MOH: 0,347- KKOH: 0,786- R: 0,902 olarak bulunmuştur. Bu iki model sonucu karşılaştırıldığında DVM, ÇDR modeline göre akış miktarı tahminin de daha iyi sonuç vermiştir.

Sugeno-BM modeli sonucunda MOH: 0,345- KKOH: 0,782- R: 0,903 sonuçlarına ulaşılmıştır. Mamdani-BM’ta ise MOH: 0,338- KKOH: 0,771- R: 0,917 sonuçları bulunmuştur. Sugeno-BM ve Mamdani-BM sonuçları karşılaştırıldığında Mamdani-BM modeli ve Sugeno-BM modeli birbirlerine çok yakın sonuçlar vermiştir.

5.SONUÇ ve ÖNERİLER

Bu çalışmada, çalışma alanı olarak Amerika Birleşik Devletleri'nin Sterling şehrinde bulunan Worcester ilçesindeki Stillwater nehri civarındaki Massachusetts-Rhode Island Su Bilim Merkezi tarafından yönetilen bir istasyona ait veriler kullanılmıştır. Kullanılan veriler USGS (United States Geological Survey) web sayfasından alınmıştır.

İstasyona ait 2014-2017 yılları arasındaki 3 yıllık toplamda 1095 tane meteorolojik veri kullanılmıştır. Kullanılan veriler %75 eğitim, %25 test olarak ayrılmıştır. Bu meteorolojik veriler kullanılarak nehirde akış tahmini yapılmaya çalışılmıştır.

Nehirde akış tahmini için DVM, ÇLR ve bulanık mantık modelleri kullanılmıştır. Modeller korelasyon katsayısı (R), ortalama mutlak hata (MOH) ve karesel hataların ortalamasının karekökü (KKOH) kriterlerine göre değerlendirilmiştir. Model sonuçlarının performansları karşılaştırılmıştır.

Ortalama sıcaklık (T_{ort}), yağış (P), debi zaman serisi (T-1) ve debi (m^3/s) parametreleri kullanılarak modeller oluşturulmuştur. Ortalama sıcaklık (T_{ort}), yağış (P), debi zaman serisi (T-1) girdi parametreleri, debi (m^3/s) çıktı parametresi olarak kullanılmıştır.

Modellerde çıkan sonuçlar kendi içlerinde değerlendirildiğinde verdikleri sonuçların iyi durumda olduğu gözlemlenmiştir.

Tüm model sonuçlarında eğitim ve test verileri analizlerinin karşılaştırılması sonucunda MOH, KKOH ve R kriterlerine göre, ÇLR modelinin diğer modellere göre daha düşük performans gösterdiği gözlemlenmiştir.

Bulanık mantık yöntemleri için eğitim ve test verilerinin analizleri sonucu MOH, KKOH ve R parametreleri karşılaştırıldığında Mamdani-BM model sonucu ve Sugeno-BM model sonucu birlerine çok yakın sonuçlar vermiştir.

DVM modeli eğitim ve test verileri analizleri tahminlerinde ise ÇLR modeli tahminlerine kıyasla daha iyi sonuçlar göstermiştir.

Sonuç olarak nehirde akış tahmini yapılmasında kullanılan yöntemlerin hepsi kullanılabilir durumdadır ve hepsi iyi sonuçlar vermiştir. Destek vektör makineleri, bulanık mantık ve çoklu doğrusal regresyon modelleri nehirde akış tahmini yapılmasında tavsiye edilebilir.

Nehirlerdeki akış, çok deęişkenli doğrusal olmayan bir olaydır. Bu nedenle nehirlerdeki akışın tüm parametrelerini doğru olarak belirlemek ve parametrik modelleme yapmak çok zordur. İleri ki çalışmalar için yapay zeka tekniklerinin, geçmiş mevsimsel parametrelere baęlı olarak su kaynakları ile ilgili çalışmalarda, bunların planlanmasında ve akış miktarının belirlenmesinde kullanılabileceęi düşünölmektedir.



KAYNAKLAR

- Akın, M., ve Akın, G. (2007). Suyun önemi, Türkiye’de su potansiyeli, su havzaları ve su kirliliği. *Ankara Üniversitesi Dil ve Tarih-Coğrafya Fakültesi Dergisi*, 47, 2, 105-118
- Akyılmaz, O. (2005). Esnek hesaplama yöntemlerinin jeodezide uygulamaları, Doktora Tezi, *İ.T.Ü. Fen Bilimleri Enstitüsü*, İstanbul.
- Altaş, İ. H. (1999). Bulanık Mantık: Bulanıklılık kavramı. *Enerji, Elektrik, Elektromekanik*. 3e, 62, 80-85.
- Anusree, K., ve Varghese, K.O. (2016). ANFIS, YSA ve MNLR modelleri kullanılarak Karuvannur Nehir havzasının akış tahmini. *Prosedür Teknolojisi*, 24, 101-108.
- Atalay, İ. (1974). Yüzeysel akışa geçen su miktarının tayin edilmesi. *Türk Coğrafya Dergisi*, 26, 135-145.
- Bahadır, E. (2017). Bulanık mantık yaklaşımının eğitim çalışmalarında kullanılmasının alan yazın ışığında değerlendirilmesi. *Uluslararası Sosyal ve Eğitim Bilimleri Dergisi*, 4(7), 28-42.
- Badrzadeh, H., Sarukkalige, R., ve Jayawardena, A. W. (2018). Hibrit dalgacık nöro-bulanık model ile aralıklı akış tahmini ve modellemesi. *Hidroloji Araştırması*, 49 (1), 27-40.
- Belvederesi, C., Dominic, J. A., Hassan, Q. K., Gupta, A., ve Achari, G. (2020). Yapay zeka tabanlı sıralı uyarlanabilir nöro-bulanık çıkarım sistemi kullanarak nehir akışını tahmin etme. *Su*, 12(6), 1622.
- Bisht, D. C., ve Jangid, A. (2011). Discharge modelling using adaptive neuro-fuzzy inference system. *International Journal of Advanced Science and Technology*. 31(1), 99-114.
- Bölük, O. (2020). Yağış-akış ilişkisinin yapay zekâ teknikleri kullanılarak tahmini, Yüksek Lisans Tezi, *İskenderun Teknik Üniversitesi Mühendislik ve Fen Bilimleri Enstitüsü*, Hatay
- Çolak, E. (2014). Korelasyon analizi, Eskişehir Osman Gazi Üniversitesi, Tıp Fakültesi, Eskişehir
- Dalı, İ. M. A. (2010). Parametrik havza modellemesi ile akım tahmini: Köprüçay Nehri havzası, Doktora Tezi, *Süleyman Demirel Üniversitesi Fen Bilimleri Enstitüsü*, Isparta
- Doğan, S. (2020). Günlük buharlaşma miktarının yapay sinir ağları metotları ve klasik yöntemlerle tahmini, Yayımlanmış Yüksek Lisans Tezi, *İskenderun Teknik Üniversitesi Mühendislik ve Fen Bilimleri Enstitüsü*, Hatay

- Eray, O. (2008). Destek vektör makineleri ile ses tanıma uygulaması. Yüksek Lisans Tezi, *İskenderun Teknik Üniversitesi Mühendislik ve Fen Bilimleri Enstitüsü*, Hatay
- Farboudfam, N., Ghorbani, M. A., ve Alami, M. T. (2009). Genetik programlama kullanarak nehir akış tahmini. *Su ve Toprak Bilimi*, 19 (1), 107-123.
- Fırat, M. (2007). Artificial intelligence techniques for river flow forecasting in the Seyhan river catchment, Turkey. *Hydrology and Earth System Sciences Discussions*, 4 (3), 1369-1406.
- Fırat, M. (2008). Nehir akış tahmini için yapay zeka tekniklerinin karşılaştırılması. *Hidroloji ve Yer Sistem Bilimleri*, 12 (1), 123-139.
- Gündüz, A. (2011). Fırat-Dicle havzasında günlük nehir akımlarının farklı yapay zeka yöntemleri ile tahmini, Yüksek Lisans Tezi, *Fırat Üniversitesi Fen Bilimleri Enstitüsü*, Elazığ
- Güner, N., ve Çomak, E. (2011). Mühendislik öğrencilerinin matematik I derslerindeki başarısının destek vektör makineleri kullanılarak tahmin edilmesi. *Pamukkale Üniversitesi Mühendislik Bilimleri Dergisi*, 17 (2), 87-96.
- He, Z., Wen, X., Liu, H., and Du, J. (2014). A comparative study of artificial neural network, adaptive neuro fuzzy inference system and support vector machine for forecasting river flow in the semiarid mountain region. *Journal of Hydrology*, 509, 379-386.
- İnternet: İstanbul Su ve Kanalizasyon İdaresi URL www.iski.istanbul
Son Erişim Tarihi:10.01.2021
- İnternet: www.hurriyet.com.tr/gundem/cevre-raporu-su-79-kirli-40857711
Son Erişim Tarihi:04.05.2021
- İnternet: USGS. URL <https://www.usgs.gov/>. Son Erişim Tarihi:15.05.2021
- İnternet:<https://tr.climate-data.org/kuzey-amerika/amerika-birlesik-devletleri/massachusetts/worcester-1738/> Son Erişim Tarihi: 12.05.2021
- İnternet: Wikipedia URL <http://tr.wikipedia.org/> Son Erişim Tarihi: 12.05.2021
- İyi, P., & Erol, H. (2008). Çoklu lineer regresyonda en iyi model seçimi. *ÇÜ Fen Bilimleri Enstitüsü*, 17 (5), 48-56.
- Kale, S., Ejder, T., Hisar, O., and Mutlu, F. (2016). İklim değişikliğinin Bakırçay Nehrinin yıllık akışı üzerine etkisi. *Adıyaman Üniversitesi, Bilim Dergisi*, 157-158
- Karaeminoğulları, A. B. (2020). Nehirlerdeki katı madde miktarının destek vektör makinesi modeli ile tahmini, Yüksek Lisans Tezi, *İskenderun Teknik Üniversitesi, Mühendislik ve Fen Bilimleri Enstitüsü*, Hatay

- Karataş, İ. (2018). Bulanık mantık ile klasik ve sembolik mantık ilişkisi Karşılaştırılması. *European Journal of Educational and Social Sciences*, 3 (2), 144-163.
- Keskenler, M. F., ve Keskenler, E. F. (2017). Bulanık mantığın tarihi gelişimi. *Takvim-i Vekayi*, 5 (1), 1-10.
- Keskin, L. (2020). Yağış–Akış ilişkisinin yapay sinir ağları ve otoregresif hareketli ortalamalar modelleri ile tahmini, Yüksek Lisans Tezi, *İskenderun Teknik Üniversitesi, Mühendislik ve Fen Bilimleri Enstitüsü*, Hatay
- Keskin, M. E. ve Taylan, D. (2009). Türkiye'nin güneyinde havzalar arası akış tahmini için yapay modeller. *Hidrolojik Mühendislik Dergisi*, 14 (7), 752-758.
- Körlü, S. (2019). Yeraltı suyu seviye değişiminin bulanık mantık ve destek vektör makineleri yöntemleri ile tahmini, Yüksek Lisans Tezi, *İskenderun Teknik Üniversitesi, Mühendislik ve Fen Bilimleri Enstitüsü*, Hatay
- Mamdani, E. H., and Assilian, S. (1975). An experiment in linguistic synthesis with a fuzzy logic controller. *International Journal of Man-Machine Studies*, 7 (1), 1-13.
- Mutluhan, A., ve Galip, A. (2017). Suyun önemi, Türkiye'de su potansiyeli, su havzaları ve su kirliliği. *Ankara Üniversitesi Dil ve Tarih-Coğrafya Fakültesi Dergisi*, 47 (2).
- Özdülkar, K., Fatih, Ü., Demirci, M., & Kaya, Y. Z. (2019). Günlük buharlaşma miktarının bulanık mantık yöntemleri kullanılarak bölgesel olarak modellenmesi. *Osmaniye Korkut Ata Üniversitesi Fen Bilimleri Enstitüsü Dergisi*, 2 (1), 23-29.
- Özger, M. (2009). Akış tahmini için bulanık çıkarım sistemlerinin karşılaştırılması. *Hidrolojik Bilimler Dergisi*, 54 (2), 261-273.
- Rezaei, M., Motlaq, A. A. A., Mahmoudi, A. R. ve Mousavi, S. H. (2015). Yapay sinir ağı kullanarak nehir akışı tahmini. *Ciência e Natura*, 37 (6-1), 207-215.
- Saplıoğlu, K., & Çimen, M. (2010). Yapay sinir ağlarını kullanarak günlük yağış miktarının tahmini. *Mühendislik Bilimleri ve Tasarım Dergisi*, 1 (1), 14-21.
- Sönmez, O., Çeribaşı, G. ve Doğan, E. (2016). Farklı sinir ağı yaklaşımları ve trend analizi yöntemleriyle kısa ve uzun vadeli akış tahmini: Sakarya Nehri vaka çalışması, Türkiye. *Fresen. Environ. Bull*, 25, 565-579.
- Taşar, B., Unes, F., & Varcin, H. (2019). Prediction of the rainfall–runoff relationship using neuro fuzzy and support vector machines. In 2019 “Air and Water–Components of the Environment” Conference Proceedings, 237-246.
- Tortum, A., Yayla, N., & Gökdağ, M. (2003). Yapay sinir ağları ve birleştirilmiş sinirsel bulanık sistemler ile şehirlerarası yük taşıması tür seçiminin modellenmesi, Doktora Tezi, *Atatürk Üniversitesi*, Erzurum

- Uamusse, M. M., Ndalila, P., Tsamba, A. J., de Oliveira Carvalho, F. ve Person, K. (2015). Dalgacık yöntemi kullanılarak küçük hidroelektrik santrali için Pungwe Nehri'nde aylık akım akış tahmini. *Uluslararası Enerji ve Güç Mühendisliği Dergisi*, 4, 280-286.
- Üneş, F., Demirci, M., Zelenakova, M., Çalışıcı, M., Taşar, B., Vranay, F., ve Kaya, Yz (2020). Yapay zeka ve bulanık teknikler kullanılarak nehir akışı tahmini. *Su*, 12 (9), 2427.
- Vapnik, V. N. (1995). The nature of statistical learning. *Theory*.
- Yadav, A., Prasad, B. B. V. S. V., Mojjada, R. K., Kothamasu, K. K. ve Joshi, D. (2020). Application of artificial neural network and genetic algorithm based artificial neural network models for river flow prediction, *Rev, d'Intelligence Artif.*, 34 (6), 745-751.
- Yarar, A. (2014). Aylık akış verilerini tahmin etmek için bir hibrit dalgacık ve nöro-bulanık model. *Su Kaynakları Yönetimi*, 28 (2), 553-565.
- Yılmaz, M., ve Arslan, E. (2005). Bulanık mantığın jeodezik problemlerin çözümünde kullanılması. Harita ve Kadastro Mühendisleri Odası, Mühendislik Ölçmeleri STB Komisyonu, 2, 23-25.

DİZİN

A

Akış ·

i,51,viii,x,xi,1,2,3,4,5,6,7,8,9,
10,13,15,2835,36,3738,39,40,
41,42,43,44,45,46,47,48,49,50
,51

Ampirik ·

1,2

B

Bulanık Mantık ·

i,iii,vi,viii,ix,5,6,9,10,15,19,
20,21,24,2526,27,28,35,36,48,
50,51**Ç**

ÇDR ·

vi,x,16,17,18,35,36,37,38,46
,47**D**

Debi ·

ix,4,5,7,10,13,15,35,36,39,41,
44,47,48

Debi Zaman Serisi ·

35,36,39,41,44,47,48

DVM ·

vi,vii,xi,28,29,32,35,36,4445,
46,47,48**H**

HİDROLOJİK ·

ix,3,4,9,50

K

KKOH ·

xiii,35,36,46,47,48

M

Meteorolojik Veri

11,48

Model ·

i,iii,iv,vi,vii,viii,xii,5,6,7,8,9
,10,15,16,17,18,20,21,25,26,2
7,29,35,3637,38,39,40,41,42,4
3,44,45,46,47,48,49,50

MOH ·

xiii,35,36,46,47,48

O

Ortalama Sıcaklık ·

xii,10,13,14,15,35,36,39,41,
44,47,48

Tahmin·

51,viii,4,5,6,7,8,9,10,13,15,
17,18,35,36,46,47,48,49,50,51**Y**

Yağış ·

iii,ix,1,3,4,5,6,7,8,9,10,12,13,
14,15,35,36,39,41,44,47,48,49
,50,51



TEKNOVERSİTE



teknoversite **AYRICALIĞINDASINIZ**

İSTE

